

Hochschule Darmstadt

– Fachbereich Mathematik und
Naturwissenschaften & Informatik –

Erkennung von Leistungsverlust beim Klettern durch IMU-Sensordaten: Studienbasierte Datenerhebung mit einem Multi-Sensor-Aufzeichnungssystem und Modellentwicklung

Abschlussarbeit zur Erlangung des akademischen Grades

Master of Science (M. Sc.)

im Studiengang Data Science

vorgelegt von

Danilo Zähle

Matrikelnummer: 1126631

Referent : Prof. Dr. Timo Schürg

Korreferent : Prof. Dr. Kawa Nazemi

Ausgabedatum : 01.04.2025

Abgabedatum : 30.09.2025

ERKLÄRUNG

Ich versichere hiermit, dass ich die vorliegende Arbeit selbstständig verfasst und keine anderen als die im Literaturverzeichnis angegebenen Quellen benutzt habe.

Alle Stellen, die wörtlich oder sinngemäß aus veröffentlichten oder noch nicht veröffentlichten Quellen entnommen sind, sind als solche kenntlich gemacht.

Die Zeichnungen oder Abbildungen in dieser Arbeit sind von mir selbst erstellt worden oder mit einem entsprechenden Quellennachweis versehen.

Diese Arbeit ist in gleicher oder ähnlicher Form noch bei keiner anderen Prüfungsbehörde eingereicht worden.

Darmstadt, 29. September 2025

Danilo Zähle

ABSTRACT

This master's thesis addresses the detection and prediction of fatigue in climbing using Inertial Measurement Unit (IMU) sensor data. The work pursues two main objectives: the generation of a novel study-based dataset and the subsequent development of a data-driven predictive model for the fatigue state.

To generate the data, a controlled study was conducted with ten participants. The subjects were equipped with a self-developed multi-sensor recording system to capture movement data using IMU sensors while climbing. The progressive fatigue development over time was quantified as the target variable through several objective force measurements and subjective questionnaires. A central contribution of the work is the creation of a transparent and reproducible dataset which will be made publicly available after the study's conclusion to ensure the reproducibility of the results and facilitate future research.

Two different machine learning model architectures were developed and compared to predict fatigue. The first architecture is a feature-based regression model using XGBoost. Relevant features, such as movement amplitudes and frequency components, were manually extracted from the IMU time series. The second architecture is a raw data-based deep learning model with an attention mechanism, which operates directly on the unprocessed sensor data. The attention mechanism allows the model to automatically identify and weight the most important movement patterns for the prediction.

The results demonstrated a significant superiority of both models compared to simple baseline approaches, particularly in the accuracy of the prediction values. The XGBoost model identified that frequency features of leg movements possessed the highest predictive power for fatigue. The attention model yielded the best prediction results and exhibited good generalization ability. This work confirms the potential of IMU sensor data in conjunction with advanced machine learning methods for the objective assessment of performance loss in climbing.

ZUSAMMENFASSUNG

Diese Masterarbeit befasst sich mit der Erkennung und Vorhersage von Ermüdung im Klettersport unter Verwendung von IMU-Sensordaten. Die Arbeit verfolgt zwei Hauptziele: die Generierung eines neuartigen, studienbasierten Datensatzes und die darauf aufbauende Entwicklung eines datenbasierten Vorhersagemodells für den Ermüdungszustand.

Zur Datenerhebung wurde eine kontrollierte Studie mit zehn Probanden durchgeführt. Mithilfe eines eigenentwickelten Multi-Sensor-Aufzeichnungssystems wurden die Bewegungsdaten während des Kletterns durch IMU-Sensoren erfasst. Die progressive Ermüdung über die Zeit hinweg wurde dabei durch objektive Kraftmessungen und subjektive Befragungen als Zielgröße quantifiziert. Ein zentraler Beitrag der Arbeit ist die Schaffung eines transparenten und nachvollziehbaren Datensatzes, der nach Abschluss der Studie öffentlich zugänglich gemacht wird, um die Reproduzierbarkeit der Ergebnisse zu gewährleisten und zukünftige Forschung zu ermöglichen.

Zur Vorhersage der Ermüdung wurden zwei unterschiedliche Modellarchitekturen entwickelt und verglichen. Die erste Architektur ist ein Feature-basiertes Regressionsmodell mit XGBoost. Hierbei wurden relevante Merkmale wie Bewegungsamplituden und Frequenzkomponenten manuell aus den IMU-Zeitreihen extrahiert. Die zweite Architektur ist ein Rohdaten-basiertes Deep-Learning-Modell mit Attention-Mechanismus, das direkt auf den unverarbeiteten Sensordaten arbeitet. Der Attention-Mechanismus ermöglicht es dem Modell, die für die Vorhersage wichtigsten Bewegungsmuster automatisch zu identifizieren und zu gewichten.

Die Ergebnisse zeigten eine signifikante Überlegenheit beider Modelle gegenüber einfachen Baseline-Ansätzen, insbesondere bei der Genauigkeit der Vorhersagewerte. Das XGBoost-Modell identifizierte, dass Frequenzmerkmale der Beinbewegungen die höchste Vorhersagekraft für die Ermüdung besaßen. Das Attention-Modell erzielte die besten Vorhersageergebnisse und zeigten eine gute Generalisierungsfähigkeit. Die Arbeit bestätigt damit das Potenzial fortschrittlicher Machine-Learning-Verfahren zur Entwicklung objektiver Monitoring-Tools für die Leistungsbeurteilung und Trainingssteuerung im Klettersport.

INHALTSVERZEICHNIS

I Thesis

1	Einleitung	1
2	Theoretische Grundlagen	3
2.1	Grundlagen des Kletterns und Boulderns	3
2.2	Metriken in der Sportwissenschaft	6
2.3	Inertial Measurement Unit (IMU)	8
2.4	Modellierung	10
3	Verwandte Arbeiten	13
4	Studie zur Sensordatenaufzeichnung mit Probanden	16
4.1	Ziel der Studie	16
4.2	Probanden	17
4.3	Auswahl des zu kletternden Boulderproblems	17
4.4	Sensormessung während des Kletterns	18
4.5	Messung der Ermüdung	19
4.6	Zeitlicher Ablauf	23
4.7	Multi-Sensor-Aufzeichnungssystem	25
5	Methodik	33
5.1	Datenvorverarbeitung	33
5.2	Modellentwicklung	50
5.3	Evaluationsverfahren	53
6	Ergebnisse	55
6.1	Datensatz	55
6.2	Modellergebnisse	57
7	Diskussion	62
7.1	Diskussion der Ergebnisse	62
7.2	Einschränkungen	64
8	Fazit	66
8.1	Fazit	66
8.2	Ausblick	67

II Appendix

A	Appendix	69
A.1	Python Versionen und Abhängigkeiten	69
A.2	Hyperparameter	69
A.3	Ergebnisse der Leave-One-Subject-Out Cross-Validation	73

	Literatur	75
--	-----------	----

ABBILDUNGSVERZEICHNIS

Abbildung 2.1	Kilterboard mit 40° Winkel, die leuchtenden Griffe markieren die Route des Boulderproblems	4
Abbildung 2.2	Darstellung verschiedener Grifftechniken: Slope (a), Half-Crimp (b), Full-Crimp (c) [3]	5
Abbildung 2.3	Verschiedene Zeitpunkte der RFD Berechnung in einer typischen Kraft-Zeit-Kurve [30]	7
Abbildung 4.1	Positionen der Sensoren an Handgelenke, Hüfte und Knöchel	19
Abbildung 4.2	Aufhängung eines Dynamometers mit Griff-Holzblock	20
Abbildung 4.3	Verwendete Griffe, an denen der Klimmzug ausgeführt wird	21
Abbildung 4.4	Offizielle Darstellung der ROF-Skala als Veranschaulichung für die Probanden	22
Abbildung 4.5	Anstrengungsskala Sport (ASS)	23
Abbildung 4.6	Gleitender Durchschnitt (Fenster 5 min) der Beschleunigung (links) und des Gyroskops (rechts) von 6 Sensoren über eine Zeit von 4,5 h	31
Abbildung 4.7	Gleitender Durchschnitt (Fenster 5 min) des Winkels (links) und der Quaternionen (rechts) von 6 Sensoren über eine Zeit von 4,5 h	32
Abbildung 5.1	Die gemessene Maximalkraft der Probanden getrennt für links (blau) und rechts (rot)	34
Abbildung 5.2	Kraftkurven der RFD Messungen aller Probanden . . .	35
Abbildung 5.3	Berechnete RFD_{200ms} der einzelnen Probanden über mehrere Versuche	36
Abbildung 5.7	Automatische Erkennung von Bergstart und -ende in einer Kraftkurve mit adaptiver Basisline	37
Abbildung 5.4	Geschwindigkeitskurve mit klar erkennbarer positiver Komponente	38
Abbildung 5.5	Geschwindigkeitskurve ohne klar erkennbarer positiver Komponente	38
Abbildung 5.6	Geschwindigkeitskurve mit unrealistisch langer positiver Phase	38
Abbildung 5.8	Oben: Einem Zeitstempel sind mehrere Messwerte für $AccX$ zugewiesen. Unten: Nach der Korrektur, die Messwerte sind gleichmäßig zwischen den Zeitstempeln verteilt.	44

Abbildung 5.9	Werteverteilung für die Beschleunigungswerte $AccX$, $AccY$ und $AccZ$ (Einheiten in g). Beide Werteverteilung vor der Ausreißerentfernung. Bei der rechten Grafik wurden die Ausreißer zur besseren Darstellung ausgeblendet.	45
Abbildung 5.10	Anzahl der aufeinanderfolgenden Messungen der Beschleunigung über einen positiven Schwellwert	46
Abbildung 5.11	Anzahl der aufeinanderfolgenden Messungen der Beschleunigung über einen negativen Schwellwert	46
Abbildung 5.12	Unterschiedlich lange Zeitreihen pro Proband nach Verkettung der Versuche	49
Abbildung 5.13	Überlappende Segmente für eine gegebene Segmentlänge und Fensterschritt	49
Abbildung 5.14	Architektur eines hybriden CNN Multi-Head-Attention-Modells	52
Abbildung 6.1	Der Ermüdungsindex aus einer Kombination der Kraftparameter. Je höher der Ermüdungsindex, desto höher die Ermüdung.	56

TABELLENVERZEICHNIS

Tabelle 4.1	Demografische Daten der Probanden	17
Tabelle 4.2	Zeitlicher Ablauf der Übungen	24
Tabelle 5.1	Übersicht der gemessenen Klettervorgänge pro Proband	41
Tabelle 5.2	Deskriptive Statistik der Sensormesswerte über alle Messungen hinweg	42
Tabelle 5.3	Anzahl aller identischer Zeitstempel und Vorkommen im Datensatz	43
Tabelle 6.1	Deskriptive Statistik des erstellten Datensatzes der Sen- sormessungen	55
Tabelle 6.2	Ergebnisse des XGBoost-Modells unterschiedlichen Da- tensätzen und der Baseline Modelle	57
Tabelle 6.3	Feature importance des XGBoost-Modells mit Mini- malFCParameters	58
Tabelle 6.4	Feature importance des XGBoost-Modells mit Efficient- FCParameters	58
Tabelle 6.5	Feature importance des XGBoost-Modells mit Efficient- FCParameters + Körperrelation	59
Tabelle 6.6	Ergebnisse des Attention-Modells	60
Tabelle A.1	Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit MinimalFCParameters . .	73
Tabelle A.2	Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit EfficientFCParameters . .	73
Tabelle A.3	Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit EfficientFCParameters + Körperrelation	74
Tabelle A.4	Ergebnis der Leave-One-Subject-Out Cross-Validation für das beste Attention-Modell (Segmentlänge = 1000, Fensterschritt = 100)	74

ABKÜRZUNGSVERZEICHNIS

ASS Anstrengungsskala Sport

CNN Convolutional Neural Network

FFT Fast-Fourier-Transformation

IMU Inertial Measurement Unit

MAE Mean Absolute Error

MPV Mean Propulsive Velocity

RFD Rate of force development

RNN Recurrent Neural Network

ROF Rating of Fatigue

Teil I

THESIS

1. EINLEITUNG

Die objektive Beurteilung der Ermüdung stellt im Klettersport eine wesentliche methodische Herausforderung dar. Als Sportart, die komplexe motorische Koordination mit Anforderungen an Maximalkraft und Kraftausdauer vereint, führt die Akkumulation von Ermüdung zu einer Abnahme der Leistungsfähigkeit und verursacht messbare Veränderungen in der Bewegungskinetik. Diese Veränderungen wiederum können das Risiko von technischen Fehlern und Verletzungen erhöhen. Bisherige Verfahren zur Ermüdungsbewertung stützen sich überwiegend auf subjektive Skalen oder auf invasive physiologische Labormessungen (z.B. Laktat im Blut). Dies resultiert in einer Limitation der kontinuierlichen und objektiven Überwachung des athletischen Zustands während der kletterspezifischen Belastung und erschwert die datengestützte Trainingssteuerung.

IMU-Sensoren haben sich als vielversprechende Kandidaten erwiesen, um diese Lücke zu schließen. Sie erfassen Beschleunigung und Rotationen und liefern Zeitreihendaten der menschlichen Bewegung, die theoretisch die Signaturen der Ermüdung, wie nachlassende Stabilität oder veränderte Bewegungsrhythmen, abbilden können. Die wissenschaftliche Herausforderung liegt in der Anwendung fortschrittlicher Verfahren des maschinellen Lernens, um aus diesem Datenvolumen die relevanten Muster für eine Vorhersage des Ermüdungsgrades zu extrahieren.

Vor diesem Hintergrund verfolgt diese Masterarbeit zwei zentrale, miteinander verbundene Ziele: Erstens die Generierung eines neuen studienbasierten Datensatzes zur Ermüdung beim Klettern unter kontrollierten Bedingungen. Hierfür wurde eine Studie mit zehn Probanden durchgeführt, bei der ein eigenentwickeltes Multi-Sensor-Aufzeichnungssystem verwendet wurde, um IMU-Daten während der wiederholten Ausführung identischer Bouldersequenzen zu erfassen. Die Ermüdung selbst wurde dabei durch objektive Kraftmessungen und subjektive Befragungen als Zielgröße quantifiziert. Zweitens liegt der Fokus auf der Entwicklung und dem Vergleich datenbasierter Vorhersagemodelle unter Verwendung dieses neuen Datensatzes. Hierbei werden zwei unterschiedliche Modellansätze implementiert und evaluiert: ein Feature-basiertes Regressionsmodell mit XGBoost, das auf manuell erstellten Merkmalen beruht und ein Rohdaten-basiertes Deep-Learning-Modell mit Attention-Mechanismus, das die Mustererkennung automatisch vornimmt. Die Arbeit liefert damit einen Beitrag zur Methodik der sportwissenschaftlichen Sensorik, indem sie die Eignung beider Ansätze bewertet. Zudem wird der erstellte Datensatz nach Abschluss der Arbeit öffentlich zugänglich gemacht, um die Reproduzierbarkeit der Ergebnisse zu gewährleisten.

Die vorliegende Arbeit gliedert sich wie folgt: Kapitel 2 stellt die theoretischen Grundlagen vor, von der Entstehung der Ermüdung beim Klettern über relevante sportwissenschaftliche Metriken bis hin zu den Funktionsweisen der IMU-Sensoren und den Modellierungsansätzen. Kapitel 3 ordnet die Arbeit durch die Diskussion verwandter Arbeiten in den aktuellen Forschungsstand ein. Kapitel 4 beschreibt detailliert die Studie zur Sensordatenaufzeichnung mit Probanden, inklusive des Studiendesigns, des Multi-Sensor-Aufzeichnungssystems und der Methodik der Ermüdungsmessung. Kapitel 5 erläutert die Methodik der Datenvorverarbeitung und die Entwicklung der Modellarchitekturen. Kapitel 6 präsentiert die Ergebnisse der Modellierung. Abschließend diskutiert Kapitel 7 die Ergebnisse und die Einschränkungen der Arbeit, bevor Kapitel 8 die Arbeit mit einem Fazit und einem Ausblick beendet.

2. THEORETISCHE GRUNDLAGEN

2.1 GRUNDLAGEN DES KLETTERNS UND BOULDERNS

2.1.1 *Bouldern und Boulderprobleme*

Bouldern ist eine Disziplin des Kletterns, bei der an natürlichen Felsblöcken oder künstlichen Kletterwänden in Absprunghöhe geklettert wird. Typischerweise bewegt man sich in Bereichen zwischen 2 und 5 Metern Höhe, von denen man nach Abschluss der Route kontrolliert abspringen kann. Daher ist weder ein Seil noch ein Gurt erforderlich, stattdessen dienen Fallschutzmatten als Sturzsicherung [12].

Ein Boulderproblem besteht aus einer definierten Abfolge von Griffen und Tritten, die vom Start- bis zum Endgriff durchklettert werden müssen. Die Herausforderung liegt nicht in der Höhe, sondern in der technischen und körperlichen Anforderung der Bewegungssequenz. Typische Elemente beim Bouldern sind dynamische Züge, präzise Fußplatzierungen und anspruchsvolle Körperpositionen. Die Schwierigkeit eines Boulderproblems wird durch verschiedene Faktoren bestimmt, darunter Griffgröße, Neigung der Wand, Reichweite der Züge und Komplexität der Bewegungen. In Kletterhallen werden die Probleme durch farblich gekennzeichnete Griffe markiert und nach standardisierten Schwierigkeitsskalen eingestuft.

Charakteristisch für das Bouldern ist die intensive Auseinandersetzung mit einzelnen Bewegungsabläufen. Oft müssen einzelne Züge wiederholt und optimiert werden, um das Problem erfolgreich zu lösen. Dadurch verbindet das Bouldern athletische Anforderungen mit einer taktisch-analytischen Herangehensweise.

2.1.2 *Fontainebleau-Skala*

Die Fontainebleau-Skala ist das international gebräuchlichste System zur Klassifizierung des Schwierigkeitsgrads von Boulderproblemen. Die Skala wird primär zur Bewertung von Felsbouldern verwendet, hat sich jedoch auch in Kletterhallen weitgehend etabliert. Die Skala ist ordinal und progressiv aufgebaut, wobei sie mit Ziffern, Buchstaben und dem Pluszeichen eine stetig steigende Schwierigkeit abbildet (z.B., 3, 4+, 5A, 6B+) [31]. Die Ziffern 3 bis 9 stellen die Grundkategorien dar. Eine weitere Unterteilung erfolgt mithilfe der Buchstaben A, B und C, wobei A die leichteste und C die schwerste Stufe innerhalb einer Zahl ist (z.B., 6A<6B<6C). Das Pluszeichen (+) dient als Zwischenstufe und kennzeichnet eine feinere Erhöhung des Schwierigkeitsgrads (z.B., 6B ist leichter als 6B+, das wiederum leichter als 6C ist). Die Abstufungen sind subjektiv und basieren auf Konsens

und wiederholter Begehung. Die Bewertung berücksichtigt eine Vielzahl von Faktoren, die zur technischen und physischen Anforderung eines Problems beitragen, darunter die Größe und Form der Griffe, der Winkel der Wand, die erforderliche Kraftausdauer und die Komplexität der Bewegungen. Die Fontainebleau-Skala ermöglicht somit eine standardisierte Kommunikation über die Anforderungen eines Boulderproblems [31].

2.1.3 Kilterboard

Das Kilterboard (siehe Abb. 2.1) ist eine standardisierte Trainingswand, die sich durch ihren einheitlichen Aufbau und digitale Steuerungsmöglichkeiten auszeichnet. Als modular aufgebautes System verfügt jedes Kilterboard weltweit über exakt die gleiche Anordnung von Klettergriffen in einem symmetrischen Raster. Diese konsistente Gestaltung ermöglicht die Nutzung identischer Boulderprobleme an unterschiedlichen Standorten. Über eine Smartphone-App können sich Benutzer mit dem Kilterboard verbinden und aus einer Datenbank Boulderprobleme auswählen. Nach der Auswahl leuchten die entsprechenden Griffe an der Wand auf, wodurch die zu benutzenden Haltepunkte visuell gekennzeichnet sind. Dieses System erleichtert das selbstständige Training und ermöglicht eine präzise Umsetzung der vorgegebenen Bewegungsabläufe.

Die Neigung der Wand lässt sich stufenlos zwischen einer vertikalen (0°) und stark überhängenden (70°) Position einstellen. Durch diese Verstellbarkeit des Kilterboards kann der Schwierigkeitsgrad variiert werden. Je mehr Überhang, desto schwerer ist das Boulderproblem.



Abbildung 2.1: Kilterboard mit 40° Winkel, die leuchtenden Griffe markieren die Route des Boulderproblems

2.1.4 Relevante Grifftechniken

Die Griffkraft gilt als der am häufigsten untersuchte physiologische Leistungsindikator im Klettersport. Verschiedene Studien zeigen, dass die maximale isometrische Kraft in spezifischen Grifftechniken ein entscheidender Faktor für die Kletterleistung ist [39]. Im Folgenden werden die für die Arbeit relevantesten Grifftechniken beschrieben.

Der Begriff Crimp (deutsch *Zangengriff* oder *Leistengriff*) beschreibt eine spezifische Grifftechnik, bei der die Finger in einer charakteristischen Position auf schmalen Leisten oder kleinen Griffkanten platziert werden. Diese Technik erfordert eine besondere Belastbarkeit der Fingerstrukturen und kommt vorwiegend bei kleinen Griffen zum Einsatz. Man unterscheidet hauptsächlich zwei Varianten der Crimp-Technik.




Abbildung 2.2: Darstellung verschiedener Grifftechniken: Slope (a), Half-Crimp (b), Full-Crimp (c) [3]

Full-Crimp: Bei dieser Ausführung wird das erste Fingergelenk stark gebeugt, während das Endgelenk überstreckt wird. Der Daumen wird häufig zur Unterstützung über den Zeigefinger gelegt (siehe Abb. 2.2). Diese Position ermöglicht maximale Kraftübertragung, belastet jedoch die Fingerstrukturen besonders stark.

Half-Crimp: Hier bleiben die Finger in einer neutraleren Position, bei der die ersten beiden Gelenke etwa im 90° Winkel stehen. Diese Variante gilt als biomechanisch günstiger und wird oft für Trainingszwecke empfohlen, da sie die Gelenke weniger stark beansprucht.

Die Beherrschung beider Techniken ist für fortgeschrittene Boulderer essenziell, da viele schwierige Boulderprobleme präzises Crimpen erfordern. Die Wahl der geeigneten Technik hängt von Faktoren wie Griffgröße, Wandneigung und individueller Anatomie ab.

2.1.5 Ermüdungserscheinungen beim Klettern

Ermüdung setzt sich aus zwei Hauptkomponenten zusammen: der lokalen muskulären Erschöpfung und einer Beeinträchtigung der zentralen motorischen Steuerung.

Die lokale muskuläre Ermüdung entsteht primär in der Greifmuskulatur der Unterarme infolge intensiver Belastungen [48]. Der einsetzende Kraftverlust zwingt den Kletternden, die fehlende Haltekraft durch den vermehrten Einsatz des gesamten Körpers auszugleichen. Diese Kompensationsbewegungen sind ineffizient und führen zu Abweichungen von der optimalen Kinematik.

Die zentrale Ermüdung betrifft die Steuerungsfähigkeit des Nervensystems und beeinflusst die Präzision der Bewegungen [2]. Mit zunehmender zentraler Erschöpfung nimmt die Fähigkeit zur genauen Dosierung der Kraft und zur stabilen Kontrolle des Körperschwerpunkts ab. Dies führt zu einer Zunahme der Bewegungsvariabilität und einer verminderten Flüssigkeit der Züge [2].

Solche Unregelmäßigkeiten und Schwankungen in der Bewegungsausführung sind direkt über die IMU-Sensoren erfassbar und dienen als wesentliche Merkmale für die Modellentwicklung zur Erkennung von Leistungsverlust.

2.2 METRIKEN IN DER SPORTWISSENSCHAFT

2.2.1 *Maximalkraft*

Die Maximalkraft (F_{max}) ist die höchste Kraft, die das neuromuskuläre System willkürlich erzeugen kann. Sie stellt die fundamentale Basis der menschlichen Kraftfähigkeit dar, von der alle anderen Kraftformen abhängen. Zur wissenschaftlichen Beurteilung der Maximalkraft werden primär zwei Messmethoden unterschieden: die isometrische und die dynamische Maximalkraft [22].

Die isometrische Maximalkraft misst die höchste Kraft, die ohne eine Längenveränderung des Muskels gegen einen unüberwindbaren Widerstand aufgebracht wird. Dies bedeutet, dass der Muskel zwar Kraft aufbaut und kontrahiert, sich aber dabei weder verkürzt noch verlängert. Eine Bewegung in einem Gelenk findet somit nicht statt. Ein Beispiel hierfür ist der Kraftaufbau beim Versuch, einen unbeweglichen Gegenstand zu verschieben: Es wird eine Spannung in den Muskelfasern erzeugt, während deren Länge konstant bleibt. Diese Art der statischen Kontraktion ermöglicht eine präzise Messung der maximalen statischen Kraft. Werte der isometrischen Maximalkraft sind in der Regel höher als die dynamischen Werte, da keine Überwindungs- oder Abbremsphasen stattfinden.

Die dynamische Maximalkraft bezieht sich hingegen auf die höchste Kraft, die während einer Bewegung gegen einen Widerstand erzeugt wird. Sie wird häufig durch das 1 Repetition Maximum (1RM), also das maximale Gewicht, das in einer spezifischen Übung einmal korrekt bewältigt werden kann, bestimmt. Obwohl die dynamische Maximalkraft geringere Werte liefert als die isometrische, ist sie für die Analyse sportartspezifischer Bewegungen, die eine dynamische Kraftentwicklung erfordern, von zentraler Bedeutung.

Ein hohes Niveau der Maximalkraft ist entscheidend für die Leistungsfähigkeit in vielen Sportarten. Es ermöglicht, bei sportartspezifischen, submaximalen Bewegungen einen geringeren relativen Kraftanteil aufzuwenden.

2.2.2 Rate of force development (RFD)

Die Rate of force development (RFD) ist eine zentrale mechanische Kenngröße zur Quantifizierung der Explosivkraft. Sie definiert die Geschwindigkeit, mit der ein Muskel oder eine Muskelgruppe Kraft entwickeln kann, und wird als der Quotient aus der Änderung der Kraft (ΔF) und der dafür benötigten Änderung der Zeit (Δt) beschrieben [1]:

$$RFD = \frac{\Delta F}{\Delta t} \quad (2.1)$$

Die Maßeinheit der RFD ist Newton pro Sekunde (N/s). Im Gegensatz zur Maximalkraft (F_{max}), die die absolute Kraftfähigkeit unter zeitlich unbegrenzten Bedingungen misst, erfasst die RFD die Fähigkeit zur schnellen Kraftentfaltung innerhalb der für sportliche Bewegungen typischerweise sehr kurzen Zeitfenster (z.B. < 250 ms).




Abbildung 2.3: Verschiedene Zeitpunkte der RFD Berechnung in einer typischen Kraft-Zeit-Kurve [30]

In der Forschung und Praxis werden unterschiedliche Ansätze zur Berechnung der RFD verwendet (siehe Abb. 2.3). Ein häufiger Ansatz ist die Berechnung der durchschnittlichen RFD über feste Zeitintervalle ab Beginn der Muskelkontraktion. Hierbei werden standardisierte Zeitfenster wie 0–50 ms, 0–100 ms oder 0–200 ms gewählt, um die Kraftentwicklungsrate in verschiedenen Phasen der Kontraktion zu charakterisieren. Die Aussagekraft der RFD variiert dabei in Abhängigkeit vom gewählten Messintervall. Alternativ dazu kann die RFD auch relativ zu einem bestimmten Prozentsatz der individuellen Maximalkraft ermittelt werden. Bei dieser Methode wird der Kraftanstieg bis zum Erreichen eines Schwellenwerts, beispielsweise 50% oder 80% der F_{max} , betrachtet. Dieser prozentuale Ansatz ermöglicht es, die Explosivkraft unabhängig vom absoluten Maximalkraftniveau zu bewerten

und erlaubt somit einen Vergleich des Kraftanstiegs zwischen Athleten mit unterschiedlicher Kraftkapazität. Die Wahl des spezifischen Berechnungsverfahrens ist somit kontextspezifisch und muss im Hinblick auf die jeweilige Forschungsfrage oder sportliche Anforderung getroffen werden.

2.2.3 Mean Propulsive Velocity (MPV)

Die Mean Propulsive Velocity (MPV) ist eine kinematische Messgröße, welche die durchschnittliche Geschwindigkeit während der positiven, beschleunigenden (propulsiven) Phase einer Bewegung gegen eine submaximale Last angibt [18]. Im Gegensatz zur Durchschnittsgeschwindigkeit über die gesamte konzentrische Bewegung berücksichtigt die MPV nur den Abschnitt, in dem die ausgeübte Kraft größer ist als der zu überwindende Widerstand, sodass eine positive Beschleunigung vorliegt.

Die MPV wird mithilfe von inertialen Messeinheiten (IMUs), linearen Positionswandlern oder anderen Bewegungssensoren erfasst. Die propulsive Phase beginnt, sobald die Bewegungsgeschwindigkeit nach der Umkehrphase aus der exzentrischen Bewegung positive Werte annimmt, und endet in dem Moment, in dem die Beschleunigung erstmals kleiner oder gleich null wird. Dies schließt den finalen, abbremsenden Teil der Bewegung, in dem die Muskulatur bereits deaktiviert wird, aus der Berechnung aus.

Die MPV steht in einer inversen, nicht-linearen Beziehung zum prozentualen Anteil der Maximalkraft (F_{max}). Je höher die relative Last, desto niedriger ist die MPV [18]. Dieser Zusammenhang ermöglicht es, über die Messung der Bewegungsschnelligkeit bei submaximalen Lasten indirekt Rückschlüsse auf das aktuelle Maximalkraftniveau zu ziehen. Daher wird die MPV im Krafttraining häufig zur Schätzung der Maximalkraft, zur Steuerung der Trainingsintensität und zur objektiven Quantifizierung von Ermüdung innerhalb eines Trainingssatzes genutzt.

2.3 INERTIAL MEASUREMENT UNIT (IMU)

2.3.1 Aufbau und Funktionsweise

Eine Inertial Measurement Unit (IMU) ist ein integriertes Sensorsystem zur Erfassung von Bewegungsdaten durch Kombination mehrerer unterschiedlicher Sensoren. IMUs ermöglichen die Bestimmung von Position, Orientierung und Bewegung eines Körpers im dreidimensionalen Raum ohne externe Referenzsysteme. Eine IMU besteht typischerweise aus zwei bis drei unterschiedlicher Sensortypen mit verschiedenen Messprinzipien.

Beschleunigungssensoren (Accelerometer) messen die translatorischen Beschleunigungskomponenten entlang dreier orthogonaler Raumachsen (X, Y, Z). Sie detektieren sowohl dynamische Bewegungsbeschleunigungen als auch die statische Erdbeschleunigung, wodurch die absolute Orientierung relativ zum Erdgravitationsfeld bestimmt werden kann.

Die Drehratensensoren (Gyroskope) erfassen die Winkelgeschwindigkeiten um die drei Raumachsen. Durch zeitliche Integration der Winkelgeschwindigkeiten kann die Orientierungsänderung des Systems berechnet werden, wobei dieser Ansatz durch Driftfehler limitiert ist.

Erweiterte Systeme integrieren zusätzlich Magnetometer, welche das Erdmagnetfeld in allen drei Achsen messen. Diese ermöglichen die Bestimmung der absoluten Kompassrichtung bzw. Magnetfeldausrichtung und verbessern die Langzeitstabilität der Orientierungsschätzung. Allerdings unterliegen Magnetometer Störungen durch elektromagnetische Felder in der Umgebung.

IMUs mit Accelerometer und Gyroskop erfassen mit der Beschleunigung und Drehrate für jeweils die X, Y und Z-Achse sechs Freiheitsgrade und werden mit *6DoF* (6 Degrees of Freedom) bezeichnet. Kommt zusätzlich ein Magnetometer zum Einsatz, handelt es sich um 9 Freiheitsgrade (*9DoF*).

Die kombinierte Auswertung der Sensordaten erfolgt durch Sensorfusionsalgorithmen wie z.B. Komplementärfilter, Kalman-Filter und Partikelfilter [14]. Diese Algorithmen kompensieren die jeweiligen Sensoreinschränkungen (z.B. Drift der Gyroskope, Rauschen der Accelerometer) und berechnen eine optimierte Schätzung von Position und Orientierung. Die Sensorfusion kann entweder direkt auf dem IMU-Sensor durch integrierte Prozessoren (sogenannte *Fused IMUs*) erfolgen oder muss durch den Anwender implementiert werden. Die Entwicklung und Optimierung solcher Fusionsalgorithmen stellt ein eigenes komplexes Forschungsfeld dar, das Aspekte der Signalverarbeitung, Statistik und Systemdynamik vereint [14].

2.3.2 Quaternionen

Für die Beschreibung der Orientierung eines IMU-Sensors gibt es verschiedene Ansätze. Eine klassische Möglichkeit sind Eulerwinkel, die die Orientierung durch drei aufeinanderfolgende Rotationen um die Achsen X, Y und Z des Sensors darstellen. Obwohl diese Darstellung anschaulich ist, treten Nachteile auf. Ein zentrales Problem ist das sogenannte *Gimbal Lock*, bei dem zwei Rotationsachsen zusammenfallen und ein Freiheitsgrad verloren geht [13]. Zudem sind Eulerwinkel für aufeinanderfolgende Rotationen anfällig für Rechenfehler, da mehrere Transformationen kombiniert werden müssen.

Quaternionen stellen eine Alternative dar, die diese Probleme umgeht. Ein Quaternion ist eine Erweiterung der komplexen Zahlen und wird mit vier Komponenten dargestellt. Neben der reellen Komponente q_0 enthält es drei imaginäre Anteile q_1i , q_2j und q_3k . Die Einheiten i , j und k sind imaginäre Basiszahlen, die den folgenden Rechenregeln gehorchen [13]:

$$i^2 = j^2 = k^2 = ijk = -1. \quad (2.2)$$

Ein allgemeines Quaternion hat die Form

$$q = q_0 + q_1i + q_2j + q_3k, \quad (2.3)$$

wobei q_0 die reelle und q_1, q_2, q_3 die imaginären Komponenten darstellen. Für die Beschreibung einer Rotation wird ein normiertes oder Einheitsquaternion verwendet, das die Bedingung erfüllt

$$q_0^2 + q_1^2 + q_2^2 + q_3^2 = 1. \quad (2.4)$$

Mit Quaternionen lässt sich eine Drehung im Raum ohne Mehrdeutigkeit und ohne Singularitäten darstellen. Die Rotation eines Vektors $\mathbf{v}$ aus dem Sensorkoordinatensystem in das Weltkoordinatensystem erfolgt, indem man den Vektor als reines Quaternion $\mathbf{v}_{quat} = 0 + v_xi + v_yj + v_zk$ darstellt und ihn mit dem Rotationsquaternion q und seinem Konjugierten q^* (was für ein Einheitsquaternion gleich q^{-1} ist) verknüpft:

$$\mathbf{v}_{quat,welt} = q \mathbf{v}_{quat} q^*. \quad (2.5)$$

Der rotierte Vektor $\mathbf{v}_{welt}$ im Weltkoordinatensystem entspricht dann den imaginären Komponenten des resultierenden Quaternions $\mathbf{v}_{quat,welt}$.

Die Umrechnung der Sensordaten in das Weltkoordinatensystem ist notwendig, da die IMU-Beschleunigungen und Kräfte immer relativ zu ihrem eigenen Sensorgehäuse misst. Ohne Transformation würden die Daten bei jeder Lageänderung des Sensors ihre Bedeutung verändern. Erst durch die Projektion auf die festen Weltachsen, beispielsweise mit der Z-Achse als Referenz für die Gravitation, lassen sich die Kräfte eindeutig interpretieren und vergleichen. Dadurch ist es möglich, Bewegungen unabhängig von der aktuellen Orientierung des Sensors zu analysieren und die wirkenden Kräfte in einem globalen Rahmen korrekt zu berechnen.

2.4 MODELLIERUNG

2.4.1 XGBoost

XGBoost (eXtreme Gradient Boosting) [9] ist ein Algorithmus des maschinellen Lernens, der auf dem Gradient-Boosting-Framework [16] basiert. Das Grundprinzip von XGBoost besteht darin, eine Reihe schwacher Lernmodelle, in der Regel Entscheidungsbäume, sequenziell zu einem leistungsfähigen Ensemble-Modell zu kombinieren. In jedem iterativen Schritt wird ein neuer Baum trainiert, der die Vorhersagefehler (Residuen) der bisherigen Modelle minimiert.

Der Algorithmus verwendet eine additive Strategie, bei der jeder neue Entscheidungsbaum die Residuen aus den vorherigen Schritten kompensiert. Zur Steuerung der Modellkomplexität und zur Vermeidung von Overfitting

integriert XGBoost eine Regularisierung, die sowohl die Anzahl der Blätter als auch die Höhe ihrer Gewichtungen berücksichtigt.

Ein wesentliches Merkmal von XGBoost ist die Implementierung technischer Optimierungen. Dazu gehören die Parallelisierung der Baumkonstruktion, die eine deutliche Beschleunigung des Trainings auf großen Datensätzen ermöglicht. Durch diese Merkmale hat sich XGBoost als ein robustes und vielseitiges Modell im Bereich der Regression und Klassifikation etabliert.

2.4.2 Self-Attention, Masked-Self-Attention und Multi-Head-Attention

Im Paper *Attention Is All You Need* von Vaswani et al. [43] wird der Mechanismus der Self-Attention als zentrales Element der Transformer-Architektur eingeführt. Ein *Token* bezeichnet dabei die kleinste Verarbeitungseinheit einer Eingabesequenz, beispielsweise ein Wort oder ein Subwort. Self-Attention beschreibt ein Verfahren, bei dem jedes Element einer Eingabesequenz eine gewichtete Repräsentation aller anderen Elemente der Sequenz berechnet. Hierfür werden die Vektoren Query, Key und Value aus den ursprünglichen Eingaberepräsentationen mittels linearer Transformationen gewonnen. Formal lässt sich der Mechanismus wie folgt darstellen:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) V \quad (2.6)$$

wobei d_k die Dimension der Key-Vektoren ist. Das Gewicht, das ein Token einem anderen zuweist, ergibt sich aus dem Skalarprodukt zwischen Query und Key, das durch eine Softmax-Normalisierung in Wahrscheinlichkeiten überführt wird. Diese Wahrscheinlichkeiten dienen anschließend dazu, eine gewichtete Summe der Value-Vektoren zu bilden, wodurch jeder Token eine neue Repräsentation erhält, die seinen Kontext in Bezug auf die gesamte Sequenz reflektiert. Der Vorteil dieses Verfahrens liegt darin, dass sowohl lokale als auch weitreichende Abhängigkeiten effizient modelliert werden können, ohne dass eine sequenzielle Verarbeitung wie in RNNs erforderlich ist.

Eine besondere Variante ist die Masked-Self-Attention. Hierbei wird die Berechnung so angepasst, dass ein Token nur auf sich selbst und auf Tokens an früheren Positionen der Sequenz zugreifen kann. Der Zugriff auf spätere Tokens wird durch eine Maske blockiert, sodass nach der Softmax-Normalisierung keine Information aus zukünftigen Positionen einfließt. Auf diese Weise wird sichergestellt, dass das Modell beim Training ausschließlich aus vergangenen Informationen lernt und nicht auf Daten zugreift, die in einer realen Vorhersagesituation noch nicht bekannt wären.

Die Multi-Head-Attention erweitert dieses Konzept, indem mehrere Self-Attention Mechanismen parallel ausgeführt werden. Jeder sogenannte Head besitzt dabei eigene Parameter für die Projektionen von Query, Key und Value, sodass verschiedene Aspekte der Beziehungen innerhalb der Sequenz gleichzeitig erfasst werden können. Während ein Head etwa syntaktische

Muster hervorheben könnte, erfasst ein anderer semantische Ähnlichkeiten oder längerfristige Abhängigkeiten. Nach der parallelen Berechnung werden die Ergebnisse der einzelnen Heads konkateniert und durch eine weitere lineare Transformation in eine finale Form überführt. Diese Vorgehensweise ermöglicht es dem Modell, vielfältige Perspektiven auf die Eingabesequenz zu erlernen und so eine reichhaltigere Repräsentation zu erzeugen.

Vaswani et al. betonen, dass Multi-Head-Attention nicht nur für eine höhere Ausdrucksstärke sorgt, sondern zugleich eine effiziente Parallelisierung erlaubt, da alle Sequenzelemente simultan verarbeitet werden. Dies stellt einen fundamentalen Unterschied zu rekurrenten (RNN) und konvolutionalen (CNN) Architekturen dar, die sequenziell arbeiten und dadurch in ihrer Effizienz limitiert sind. Die Kombination aus hoher Modellierungskapazität und Parallelisierbarkeit bildet den Kern der Transformer-Architektur und erklärt maßgeblich den Erfolg moderner Sprachmodelle, die auf diesem Prinzip aufbauen.

3. VERWANDTE ARBEITEN

IMU-SENSOREN BEIM KLETTERN

Der Einsatz von IMU-Sensoren zur Analyse und Verbesserung der Kletterleistung ist ein wachsendes Forschungsgebiet. Eine zentrale Anwendung ist die Positionserkennung von Kletterern. Krumm et al. demonstrierten in ihrer Arbeit die Nutzung von IMU-Sensoren zur Ortung und Analyse von Kletterbewegungen [25]. Diese Technologie bietet eine vielversprechende Alternative zu traditionellen visuellen Systemen. Trujillo-Guerrero et al. verglichen die Genauigkeit von IMU-Sensoren mit der von markerbasierten Kamerasystemen für die Erkennung von Armbewegungen. Ihre Studie, die auf einer Kombination aus Convolutional Neural Networks (CNN) und Transformern basiert, zeigte, dass IMUs eine präzise Alternative darstellen können [42]. Koller et al. verwendeten ebenfalls IMU-Sensoren für die Positionsbestimmung von Händen und Füßen beim Bouldern und verglichen diese mit optischen Marken [23].

Ein weiterer Schwerpunkt ist die Bewertung der Kletterleistung. Pansiot und Maury zeigten, dass die Qualität der Kletterbewegungen, insbesondere die Zuckungen (englisch *Jerk*), mit der Erfahrung der Kletterer korrelieren. Ihre Studie, die einen IMU im Ohr verwendete, ergab, dass erfahrenere Kletterer flüssigere Bewegungen mit weniger Zuckungen ausführen [37]. Ladha et al. entwickelten eine Software, die mithilfe von am Handgelenk getragenen Sensoren die Kletterfähigkeiten bewertet und Feedback für das Training gibt [28]. Kosmalla et al. gingen noch einen Schritt weiter, indem sie eine Methode zur automatischen Erkennung der gekletterten Route auf Basis von IMU-Daten vorstellten [24]. Boulanger et al. konzentrierten sich auf die Unterscheidung verschiedener Kletterstadien, wie zum Beispiel Ruhephasen oder aktive Kletterbewegungen, was eine detailliertere Analyse des Kletterprozesses ermöglicht [5].

IMU-SENSOREN BEI ALTERNATIVEN SPORTARTEN

Die Anwendung von IMU-Sensoren zur Ermüdungserkennung ist nicht auf das Klettern beschränkt, sondern wird auch in anderen Sportarten, insbesondere im Laufsport, erforscht. Studien wie die von Wang et al. und Marotta et al. untersuchten die Erkennung von Ermüdungserscheinungen bei Läufern mit Hilfe von IMUs [32, 47]. Auch Chang et al., Op De Beéck et al. und Schmidt et al. beschäftigten sich mit der Ermüdungserkennung bei Läufern, Joggern und Sprintern, was die Anwendbarkeit der Methode bei verschiedenen Intensitätsstufen belegt [8, 36, 38].

Besondere Aufmerksamkeit widmet die Forschung spezifischen Ansätzen zur Vorhersage von Ermüdung. Biró et al. vergleichen unterschiedliche Machine Learning Modelle für multivariaten IMU-Zeitreihendaten, um die Ermüdung und Ausdauer von Sportlern vorherzusagen, was eine personalisierte und datengestützte Trainingsplanung ermöglicht [4]. Für die Echtzeitanalyse nutzten Jiang et al. Transformer-Modelle, um Ermüdung in Echtzeit bei verschiedenen Übungen vorherzusagen [20]. Die Reduktion der benötigten Sensoranzahl ist ein weiteres wichtiges Ziel. Buckley et al. zeigten, dass eine binäre Klassifizierung von Ermüdung beim Joggen bereits mit nur einem einzigen IMU-Sensor möglich ist, was die Praktikabilität solcher Systeme erhöht [6].

Andere Studien konzentrierten sich auf die allgemeine Klassifizierung von unterschiedlichen Aktivitäten. Müller et al. nutzten IMUs zur Klassifizierung verschiedener Laufstile [35]. Auch die Kombination verschiedener Messmethoden ist ein vielversprechender Ansatz. Hwang et al. setzten multimodale Ansätze ein, die IMU-Sensoren und Elektromyographie (EMG) zur Klassifizierung von Ermüdung bei verschiedenen Übungen nutzten [19].

SPORTWISSENSCHAFT BEIM KLETTERN

Neben der technischen Analyse mit Sensoren liefern sportwissenschaftliche Studien wichtige Grundlagen für das Verständnis der Kletterleistung. Die Rate of Force Development (RFD) ist ein entscheidender Leistungsindikator. Stien et al. und Sordo-Vacas et al. belegten, dass Elite-Kletterer eine höhere RFD im Oberkörper aufweisen als weniger erfahrene Kletterer [40, 41]. Levernier et al. sowie Fanchini et al. bestätigten die Bedeutung der RFD, wobei letztere sogar Unterschiede in den Kraftprofilen von Boulderern und Outdoor-Kletterern feststellten: Boulderer verfügen tendenziell über eine höhere Maximalkraft und eine höhere RFD [15, 30]. Vereide et al. konnten anhand der Messung der Maximalkraft und RFD bei isometrischen Klimmzügen über unterschiedlichen Fähigkeitsstufen bei Kletterern unterscheiden [44].

Die Kraft in den Fingerflexoren spielt beim Klettern eine wichtige Rolle, da sie über die Ermüdung entscheidet. Michailov et al. belegten die Wichtigkeit dieser Muskelgruppe für die Leistung [33]. Sie zeigten auch, dass die maximale Kraft und die RFD in den Fingern entscheidend für die Leistungsfähigkeit sind.

IMU-SENSOREN ZUR ERKENNUNG VON ERMÜDUNG AM ARBEITSPLATZ

Die Forschung zur Ermüdungserkennung mit IMU Sensoren ist nicht auf den sportlichen Kontext beschränkt. Auch im industriellen Umfeld und bei der Arbeit ist die Überwachung der körperlichen Verfassung von Bedeutung. Zhang et al. demonstrierten ein automatisiertes System zur Überwachung der körperlichen Ermüdung von Arbeitern mit Hilfe von IMU-Sensoren [50].

Eine weitere Studie von Lambay et al. kombinierte IMU-Daten mit Herzfrequenzmessungen, um die Ermüdung von Arbeitern vorherzusagen [29].

Die Integration von Sensoren in tragbare Technologien wie Smartphones oder Exoskelette ist ebenfalls ein wichtiger Forschungsbereich. Karvekar et al. entwickelten ein datengesteuertes Modell, das Smartphone-Sensoren zur Identifizierung von Ermüdung am Arbeitsplatz nutzt [21]. Kuber et al. und Kuschan et al. untersuchten die Erkennung von Ermüdung bei Arbeiten mit Exoskeletten, was besonders relevant für die Sicherheit und Effizienz in manuellen Berufen ist [26, 27]. Zhang et al. nutzen IMU-Sensoren, um bei körperlich schwerer Arbeit anhand von Änderungen der ruckartigen Bewegungen (*Jerk*) Ermüdung zu erkennen [49].

4. STUDIE ZUR SENSORDATENAUFZEICHNUNG MIT PROBANDEN

4.1 ZIEL DER STUDIE

Das Ziel dieser Studie besteht darin, einen Datensatz zur Entwicklung eines datenbasierten Vorhersagemodells zu generieren. Dafür werden in einer Studie Probanden eingeladen, die mit IMU-Sensoren ausgestattet werden und diese während des Kletterns an einer Boulderwand tragen. Die Sensordaten erfassen die Bewegungen während des Kletterns und bilden die Grundlage für die spätere Modellierung. Des Weiteren umfasst die Studie die Erfassung von Ermüdungserscheinungen der Teilnehmenden, die durch die Belastungen durch das Bouldern verursacht werden. Die Messungen der Ermüdung dienen dabei als Zielvariable, die das Vorhersagemodell ausschließlich anhand der Sensordaten prognostizieren soll. Der Versuchsaufbau sieht vor, dass die Probanden mehrfach hintereinander dieselben Bouldersequenzen absolvieren, der jeweils eine Messung der Kraft vorausgeht. Auf diese Weise konnte die Entwicklung der Belastung und Ermüdung über mehrere Durchgänge hinweg erfasst werden.

Darüber hinaus verfolgt die Studie das Ziel, einen transparenten und nachvollziehbaren Datensatz zu erstellen. Der Datensatz soll nach Abschluss der Studie öffentlich zugänglich gemacht werden, um die Reproduzierbarkeit der Ergebnisse zu gewährleisten und weiteren Forschungsarbeiten in diesem Bereich als Grundlage zu dienen.

Die Konzeption der Studie erfolgte in Abstimmung mit einem Sportwissenschaftler, der wesentliche Beiträge zum Versuchsaufbau und zur Auswahl der Probanden leistete. Insbesondere wurden Aspekte der Belastungssteuerung, der Sicherheit und der physiologischen Validität des Experiments durch die Expertise des Sportwissenschaftlers optimiert.

4.2 PROBANDEN

	Mittelwert	Standardabweichung
Alter (Jahre)	28,00	7,02
Körpergröße (cm)	174,60	8,81
Gewicht (kg)	69,86	11,04
Klettererfahrung (Jahre)	6,67	3,00
Durchschnittliche Trainingseinheiten pro Woche in den letzten 12 Monaten	3,80	1,99

Tabelle 4.1: Demografische Daten der Probanden

An der Studie nahmen insgesamt zehn Probanden teil, darunter acht männliche und zwei weibliche Versuchspersonen. Die Auswahl der Teilnehmenden erfolgte nach festgelegten Kriterien, um die Validität und Reproduzierbarkeit der Ergebnisse zu gewährleisten.

Alle Probanden waren erfahrene Kletterer mit der Fähigkeit, Boulderprobleme im Schwierigkeitsgrad von 6A bis 7B nach der Fontainebleau-Skala zu bewältigen. Diese Einschränkung wurde aus zwei Gründen vorgenommen: Bei Anfängern wäre eine zuverlässige und wiederholbare Durchführung der Versuche an der Kletterwand möglicherweise nicht gegeben, da technische Unsicherheiten und unkontrollierte Bewegungsabläufe die Datenqualität beeinträchtigen könnten. Bei Kletterern auf professionellem Niveau ist davon auszugehen, dass Ermüdungserscheinungen erst nach einer deutlich höheren Belastung eintreten, was die Vergleichbarkeit der Ergebnisse innerhalb der Stichprobe verringern würde.

Zusätzlich mussten alle Teilnehmenden mindestens einen Klimmzug ausführen können, da im Rahmen der Studie auch Messungen mit dieser Übung durchgeführt wurden.

Von der Studie ausgeschlossen wurden Personen mit Verletzungen der oberen Extremitäten oder des Rumpfes innerhalb der letzten zwölf Monate und bei Durchführung einer Trainingssession innerhalb von 48 Stunden vor Versuchsbeginn, um Beeinträchtigungen durch akute Ermüdung oder Muskelkater zu vermeiden.

Den Probanden wurden Ablauf und Ziel der Studie und die einzelnen Übungen erklärt. Die Teilnahme an der Studie erfolgte in Übereinstimmung mit der Deklaration von Helsinki [46] freiwillig, unentgeltlich und die Probanden durften jederzeit die Studie abbrechen.

4.3 AUSWAHL DES ZU KLETTERNDEN BOULDERPROBLEMS

Jeder Proband erhielt ein individuell zugewiesenes Boulderproblem, das während sämtlicher Messdurchgänge unverändert blieb. Dadurch ist die Vergleichbarkeit zwischen den Messungen gewährleistet und Variationen zwischen unterschiedlichen Boulderproblemen werden ausgeschlossen. Die

Auswahl des passenden Boulderproblems erfolgte in Abstimmung mit jedem Probanden unter Berücksichtigung der folgenden Kriterien: Der Boulder durfte nicht zu leicht sein, da ein unterforderndes Problem für den Kletterer auch bei fortgeschrittener Ermüdung noch ohne erkennbare Leistungseinbußen bewältigt werden könnte. Gleichzeitig durfte der Boulder nicht zu schwer sein, um zu vermeiden, dass er ab einem bestimmten Ermüdungsgrad nicht mehr lösbar ist. In beiden Fällen wären die erhobenen Sensordaten nur eingeschränkt aussagekräftig, da sie keine kontinuierliche Ermüdung abbilden würden.

Alle Boulderprobleme wurden am Kilterboard mit einer 40° Neigung durchgeführt.

4.4 SENSORMESSUNG WÄHREND DES KLETTERNS

Im Studienaufbau wurden IMU-Sensoren mit 9 Freiheitsgraden (Modell WT901BLECL5.0 von wit-motion) verwendet. Die Sensoren beinhalten für alle drei Achsen Beschleunigungssensoren, Gyroskope und Magnetometer. Die Sensorfusion erfolgt bereits auf dem Sensor per Kalman-Filterung. Es wird mit einer Rate von 200 Hz gemessen.

Fünf Sensoren wurden für die Messungen beim Klettern am Kilterboard verwendet und am Probanden platziert. Zwei an den Armgelenken, zwei an den Knöcheln und einer an der Hüfte hinten (siehe Abb. 4.1). Der Kletterversuch wird mit einer Kamera aufgezeichnet.

Die Aufzeichnung der Daten wird gestartet und dem Probanden wird das Signal gegeben, dass der ausgewählte Boulder geklettert werden kann. Wenn ein Proband nicht erfolgreich bis nach oben klettert, wird der Versuch nach einer Pause von 2–3 Minuten wiederholt.



Abbildung 4.1: Positionen der Sensoren an Handgelenke, Hüfte und Knöchel

4.5 MESSUNG DER ERMÜDUNG

Die Ermüdung des Probanden wird anhand von drei objektiven Kraftmessungen (RFD, MPV, Maximalkraft) und zwei subjektiven Einschätzungen durch den Probanden (ROF und ASS) festgestellt. Die fünf Werte werden anschließend zu einer gemeinsamen Variable kombiniert (siehe Kapitel 5.1.1), die die Ermüdung angibt und nachfolgend die Zielvariable des Modells darstellt.

4.5.1 RFD-Messung

Für die Kraftmessungen wird zum einen die Rate of Force Development (RFD) ermittelt, da diese als Indikator für neuromuskuläre Ermüdung geeignet ist [11]. Des Weiteren stellt sich die RFD als Indikator für die Leistungsfähigkeit beim Klettern heraus [40, 41].

Zur Messung wird ein Dynamometer (Progressor 500 von tindeq) verwendet, das per Bluetooth mit einem Smartphone gekoppelt ist. Dort werden die Messungen gespeichert. Auf dem Smartphone wird dem Probanden ein Countdown angezeigt.

Das Dynamometer wird per Seil an ein portables Fingerboard mit einer 20 mm tiefen Leiste als Griff aufgehängt (siehe Abb. 4.2). Der Proband greift per Half-Crimp Handposition die Kante im Block, dabei liegt der Daumen seitlich an dem Block. Der Holzblock hängt auf Kopfhöhe und kann auf Wunsch des Probanden eingestellt werden. Die Probanden werden aufgefordert, nach einem Countdown so schnell und kraftvoll wie möglich zu ziehen, dabei wird der Arm nicht komplett durchgestreckt. Ein hereinspringen mit dem Körpergewicht wird untersagt. Es wird links und rechts getrennt nacheinander gemessen, die Reihenfolge wurde pro Probanden randomisiert. Es darf nach Wunsch Magnesiumcarbonat (Chalk) auf die Hände aufgetragen werden.




Abbildung 4.2: Aufhängung eines Dynamometers mit Griff-Holzblock

4.5.2 Schnellkrafttest per Klimmzug (MPV)

Der Schnellkrafttest per Klimmzug ist angelehnt an den Aufbau von Sordo-Vacas et al., bei dem die Mean Propulsive Velocity (MPV) für einen Klimmzug ermittelt wurde [40]. Dort ist ebenfalls hervorgehoben, dass die MPV wichtige kletterspezifische Merkmale wie die Muskelkraft der Finger, Ellenbogen und Schultern in einer Metrik abdeckt und die Leistung des Kletterers widerspiegelt.

Es wird ein explosiver Klimmzug nach oben durchgeführt, mit den Fingern an einer 20 mm tiefen Leiste (siehe 4.3). Währenddessen trägt der Proband einen IMU-Sensor an der Hüfte platziert, bei dem es sich auch um denselben Sensor handelt, der später an der Kletterwand verwendet wird. Der Proband hat die Einweisung bekommen, den Klimmzug so schnell und explosiv wie möglich durchzuführen. Der Klimmzug muss nicht senkrecht nach oben ausgeführt werden, es darf sich von der Leiste weggedrückt werden. Es muss nicht auf ein abfederndes Herunterkommen geachtet werden, es darf abgesprungen werden. Es darf nach Wunsch Chalk aufgetragen werden.



Abbildung 4.3: Verwendete Griffe, an denen der Klimmzug ausgeführt wird

4.5.3 *Fingermaximalkrafttest*

Michailov et al. belegten die Wichtigkeit der Fingerflexoren beim Klettern und zeigten, dass unter anderem die Maximalkraft in dieser Muskelgruppe entscheidend für die Leistungsfähigkeit ist [33]. Auch Vereide et al. schlagen die Maximalkraft als Parameter vor [44].

Mit demselben Dynamometer, Holzblock und Fingerposition wie bei der RFD-Messung wird die Fingermaximalkraft getestet. Im Gegensatz zur RFD-Messung wird die Kraft langsam und stetig aufgebaut. Der Proband wird angewiesen, innerhalb von 2–4 Sekunden die maximal mögliche Kraft kontinuierlich aufzubauen. Wenn ein Proband sein eigenes Körpergewicht hochziehen kann, wird er mit einem Gewicht in der anderen Hand zum Ausgleich ausgestattet, sodass er nicht den Boden verlässt. Der Proband wird durch verbale Zurufe zur Leistungssteigerung motiviert. Es wird links und rechts getrennt nacheinander gemessen, die Reihenfolge wurde pro Probanden randomisiert. Es darf nach Wunsch Chalk aufgetragen werden.

4.5.4 *Rating-of-Fatigue (ROF) Skala*

Zur Erfassung der subjektiven Ermüdung wurde die Rating-of-Fatigue (ROF) Skala [34] eingesetzt. Diese standardisierte Skala misst das aktuelle Ermüdungsgefühl auf einer numerischen Skala von 0 bis 10. Zur besseren Veranschaulichung ist sie mit mehreren beschreibenden Begriffen und Bildern versehen, die den Teilnehmern helfen sollen, den passenden Zahlenwert für ihr Empfinden zu finden (siehe Abb. 4.4).




Abbildung 4.4: Offizielle Darstellung der ROF-Skala als Veranschaulichung für die Probanden

Gemäß der offiziellen Anleitung der Skala wurden die Probanden zunächst gebeten, sich mit dem Aufbau der Skala vertraut zu machen. Bei der eigentlichen Bewertung sollen sie ihre Ermüdung spontan und so ehrlich wie möglich angeben. Die zentrale Vorgabe ist, dass die Antwort auf eine einzige, ganze Zahl zwischen 0 und 10 beschränkt wird. Das Abgeben von Zwischenwerten (z.B. 3 oder 4) ist, entsprechend der Skalenrichtlinie, nicht erlaubt. Zur Vereinheitlichung des Verständnisses liefert die Skala konkrete Beispiele für die Extremwerte. Ein Wert von 0 bedeutet *überhaupt nicht müde*. Dies entspricht dem Gefühl des Aufstehens nach einem erholsamen Schlaf. Ein Wert von 10 bedeutet *völlig erschöpft und am Limit*. Dies beschreibt einen Zustand maximaler Erschöpfung, wie er auftritt, wenn man sich vor Müdigkeit nicht mehr wach halten kann oder nach einem Sprint, bei dem man körperlich nicht mehr weitermachen kann.

4.5.5 Anstrengungsskala Sport (ASS)

Zur Erfassung der subjektiven Anstrengung während des Kletterns des Boulderproblems wurde die Anstrengungsskala Sport (ASS) [7] verwendet, die nach dem Klettern erfasst wurde. Die ASS wurde spezifisch für den deutschsprachigen Raum entwickelt und zeichnet sich durch ihre klare sprachliche Gestaltung aus. Im Gegensatz zu anderen Skalen verwendet sie durchgängig die komparative Deklination des Adjektivs *anstrengend* (z.B. *etwas anstrengend*, *sehr anstrengend*), was zu einer hohen begrifflichen Eindeutigkeit führt.

Gemäß der standardisierten Anleitung wurden die Probanden zunächst gebeten, sich mit der Skala vertraut zu machen. Die Bewertung erfolgte auf einer Skala von 1 (*überhaupt nicht anstrengend*) bis 10 (*so anstrengend, dass ich abbrechen muss*). Die Probanden wurden angeleitet, ihre empfundene An-

strengung spontan und ehrlich zu bewerten und sich für genau eine Zahl zu entscheiden. Die Verwendung von Zwischenwerten (z.B. 7 oder 8) war ausgeschlossen. Zur Veranschaulichung der Extrema wurden den Probanden konkrete Beispiele genannt: Eine Bewertung von 1 entspricht beispielsweise dem Anstrengungsgefühl beim gemütlichen Spaziergehen, während eine Bewertung von 10 der maximalen Anstrengung entspricht, bei der die Aktivität abgebrochen werden müsste. Die möglichen Ausprägungen der gesamten Skala sind in Abbildung 4.5 veranschaulicht.

so anstrengend, dass ich abbrechen muss	10
maximal anstrengend	9
extrem anstrengend	8
sehr anstrengend	7
anstrengend	6
mäßig anstrengend	5
wenig anstrengend	4
sehr wenig anstrengend	3
extrem wenig anstrengend	2
überhaupt nicht anstrengend	1

Abbildung 4.5: Anstrengungsskala Sport (ASS)

4.6 ZEITLICHER ABLAUF

4.6.1 Versuchsfamiliarisierung

Zwei und drei Tage vor dem Versuchstag wurden jeweils die Hälfte der Probanden zur Versuchsfamiliarisierung eingeladen. An diesem Termin wurde das Boulderproblem für jeden Probanden individuell festgelegt und die Tests zur objektiven Quantifizierung der Ermüdung vorgestellt. Die Versuchsleiter demonstrierten zunächst die korrekte Ausführung jeder Übung, bevor die Probanden diese unter Anleitung testweise durchführten. Dabei wurde besonderer Wert auf die korrekte Ausführung gelegt, die gegebenenfalls durch gezielte Korrekturen optimiert wurde. Die Versuchsfamiliarisierung war notwendig, um eine einheitliche Ausführungsqualität während des Hauptversuchs sicherzustellen. Des Weiteren ermöglicht ein Proben der Übungen verwertbare Ergebnisse am eigentlichen Versuchstag, weil die Übungen nicht zum ersten Mal ausgeführt werden und deshalb keine Effekte der Eingewöhnung störend sind.

4.6.2 Zeitlicher Ablauf am Versuchstag

Am Tag der Studiendurchführung wurden die Versuchsteilnehmer gestaffelt in Gruppen eingeladen, sodass immer 2 Teilnehmer gleichzeitig den in Tabelle 4.2 beschriebenen Zeitplan durchlaufen.

Vorgang	Dauer (min)
Eigenständiges Aufwärmen	20
Ausfüllen subjektive Ermüdung (ROF)	-
Kraftmessungen	5
Klettern mit Sensoren	5
Ausfüllen subjektive Anstrengung (ASS)	-
Eigenständiges Trainingsintervall	18
Ausfüllen subjektive Ermüdung (ROF)	-
Kraftmessungen	5
Klettern mit Sensoren	5
Ausfüllen subjektive Anstrengung (ASS)	-
Eigenständiges Trainingsintervall	18
Ausfüllen subjektive Ermüdung (ROF)	-
Kraftmessungen	5
Klettern mit Sensoren	5
Ausfüllen subjektive Anstrengung (ASS)	-
Eigenständiges Trainingsintervall	18
Ausfüllen subjektive Ermüdung (ROF)	-
Kraftmessungen	5
Klettern mit Sensoren	5
Ausfüllen subjektive Anstrengung (ASS)	-

Tabelle 4.2: Zeitlicher Ablauf der Übungen

Zu Beginn mussten sich die Teilnehmer eigenständig für 20 Minuten aufwärmen. Danach erfolgte eine Messeinheit, in der die Kletterdaten und die Ermüdung aufgenommen wurde. Danach wurde eine Trainingseinheit ohne Messung durchgeführt, in der der Proband eigenständig klettert und die Ermüdung vorantreibt. Danach erfolgte wieder eine Messeinheit. Dieser Ablauf wurde für insgesamt vier Messeinheiten wiederholt und hat das Ziel, eine kontinuierliche Ermüdung messen zu können. Der erste Messblock nach dem Aufwärmen stellt die Baseline dar, da hier angenommen werden kann, dass die Ermüdung der Probanden bei 0 liegt.

Eine Messeinheit bestand aus folgenden Schritten: Zuerst wurde die subjektive Ermüdung mittels der ROF-Skala ermittelt. Danach erfolgte die Messung der drei Kraftwerte mit jeweils einer Minute Pause dazwischen. Da-

nach wurden die IMU-Sensoren am Probanden angebracht und die Messung am Kilterboard durchgeführt. Im Anschluss wurde die subjektiv wahrgenommene Anstrengung während des Kletterns mit dem ASS-Wert erhoben.

Die Messung der Kraft und somit der Ermüdung erfolgte bewusst vor dem Klettern, damit dadurch der allgemeine Ermüdungszustand des Körpers erfasst wird. Dieser Zustand soll sich in den Sensordaten während des Kletterns widerspiegeln und bildet somit die Zielgröße für das Vorhersagemodell. Würden die Messungen erst nach dem Klettern des festgelegten Boulderproblems erfolgen, würden sie hauptsächlich die akute Erschöpfung direkt nach der Belastung abbilden. Diese kurzfristige Ermüdung wäre für das Modell jedoch weniger aussagekräftig, da sie nicht die fortbestehende Beanspruchung des Körpers, sondern lediglich die unmittelbare Belastungsreaktion messen würde.

Ein Trainingsintervall wird mit einer Länge von 18 Minuten angesetzt. Hier trainieren die Teilnehmer eigenständig in der Kletterhalle an unterschiedlichen Boulderwänden. Die Teilnehmer wurden angewiesen, ihre übliche Trainingsroutine zu absolvieren und dabei keine übermäßig langen Pausen einzulegen. Dieses Trainingsintervall war notwendig, um einen realistischen Ermüdungszustand zu erzeugen. Eine reine Abfolge mehrerer unmittelbar aufeinanderfolgender Messungen hätte vermutlich nicht zu einer ausreichenden Ermüdung geführt und wäre damit für die Zielsetzung der Studie ungeeignet gewesen. Durch das längere Training wird hingegen eine authentische Belastungssituation geschaffen, die näher an den typischen Bedingungen beim Bouldern liegt, wo die Trainingsdauer üblicherweise zwischen einer und zwei Stunden beträgt. Auf diese Weise konnte sichergestellt werden, dass die erhobenen Daten die Ermüdungsentwicklung in einem realistischen Kontext widerspiegeln.

4.7 MULTI-SENSOR-AUFZEICHNUNGSSYSTEM

Um die spezifischen Anforderungen der Studie zu erfüllen, wurde ein eigenes Aufzeichnungssystem entwickelt. Dieses Kapitel erläutert die Konzeption und Implementierung dieser Softwarelösung, beginnend mit den zugrundeliegenden Anforderungen. Anschließend wird der praktische Einsatz beschrieben, gefolgt von einer Betrachtung der systeminternen Architektur, die die asynchrone Sensorverwaltung, den Datenschreibprozess sowie Konfiguration und Logging umfasst. Abschließend werden die Ergebnisse eines Langzeittests zur Validierung der Systemzuverlässigkeit dargestellt.

4.7.1 Hintergrund

Die Sensordaten müssen während der Messung erfasst und ausgelesen werden, um sie in einem geeigneten Format zu speichern, das für die anschließende Verarbeitung geeignet ist.

Es gibt vom Sensorhersteller *wit-motion* eine Smartphone-App, mit der die Sensordaten ausgelesen werden können. Die App entspricht aber nicht den

nachfolgenden Anforderungen im Kontext der Studie. Deshalb wurde ein eigenes Multi-Sensor-Aufzeichnungssystem in Python entwickelt, das die Sensordaten misst und speichert.

4.7.2 Anforderungen

Die Studie zur Sensordatenaufzeichnung wird nur einmalig durchgeführt. Die Planung, die Einladung der Probanden und die eigentliche Durchführung sind mit einem hohen Aufwand verbunden, weswegen das Skript robust und zuverlässig funktionieren muss. Das bedeutet, bei Verbindungsabbrüchen zu den Sensoren müssen diese automatisch erneut verbunden werden. Bei dem erneuten Verbinden muss auch das Schreiben in eine Datei robust genug sein, dass dieses wieder fortgesetzt werden kann. Die Logik und das Programm müssen ausführlich getestet werden, damit am Versuchstag keine Fehler auftreten und damit Daten verloren gehen.

An den Probanden werden fünf Sensoren platziert. Das Skript muss in der Lage sein, simultan Datenströme von fünf Sensoren zu erfassen und zu verwalten.

Die Sensordaten müssen in einer geordneten und später nachvollziehbaren Art gespeichert werden, wobei das Datenformat die Zuordnung von Messwert zur Körperposition sicherstellt. Das Datenformat muss mit einer hohen Datenrate (200 Hz pro Sensor) umgehen können. Der Schreibprozess muss dabei unterbrochen werden können.

Das Zeitformat und der Zeitstempel müssen definierbar und nachvollziehbar sein, weil der Zeitstempel aus den Sensordaten synchron mit der parallelen Videoaufzeichnung sein muss.

Das Skript muss offline funktionieren, weil am Versuchstag in der Kletterhalle keine Internetverbindung vorhanden sein kann.

4.7.3 Anwendung

Der Aufruf des Skripts erfolgt über die Kommandozeile.

```
python3 main.py [-n NAME] [-s SENSOR_GROUP]
```

Die optionalen Argumente ermöglichen eine Anpassung der Messung:

- `-n NAME`: Vergibt einen beschreibenden Namen für die Messung (z.B. Probanden-ID oder Versuchsbezeichnung), der dem Zeitstempel im Dateinamen hinzugefügt wird
- `-s SENSOR_GROUP`: Wählt eine bestimmte Gruppe an IMU-Sensoren aus der Konfigurationsdatei aus, falls mehrere Gruppen definiert sind (siehe Kapitel [4.7.4.5](#))

Nach dem Start durchläuft das System automatisch folgende Phasen:

1. **Initialisierung:** Das Programm erstellt ein neues Verzeichnis mit dem aktuellen Zeitstempel (Format: YYYY-MM-TT_HH-MM-SS) im angegebenen Dateipfad. Optional wird der übergebene Name angehängt.
2. **Sensorverbindung:** Das System beginnt automatisch mit der Suche und Verbindung der konfigurierten IMU-Sensoren. Die Fortschrittsmeldungen werden in Echtzeit auf der Konsole ausgegeben.
3. **Datenerfassung:** Sobald alle Sensoren verbunden sind, beginnt die kontinuierliche Aufzeichnung und Speicherung.
4. **Beendigung:** Die Messung wird durch die Eingabe von STRG+C beendet. Das System initiiert dann einen geordneten Shutdown Prozess.

Während des Betriebs werden alle wichtigen Ereignisse sowohl auf der Konsole als auch in einer Logdatei im Messverzeichnis protokolliert. Bei Verbindungsabbrüchen versucht das System automatisch, die Verbindung wiederherzustellen, ohne dass Benutzerinteraktion erforderlich ist.

4.7.4 *Aufbau*

4.7.4.1 *Python Schnittstelle zum Sensor*

Der verwendete IMU-Sensor war nur unzureichend dokumentiert. Es wurde lediglich ein öffentliches GitHub Repository des Herstellers WitMotion [45] gefunden, bei dem für verschiedene Programmiersprachen Beispielskripte vorhanden sind, die eine Schnittstelle zum Sensor demonstrieren.

Unter anderem ist auch ein in Python implementiertes Beispielskript vorhanden. In diesem wird die Python-Bibliothek *bleak* verwendet, um mit dem Sensor eine Bluetooth Verbindung aufzubauen. Es werden die Rohdaten per Bluetooth übertragen, byteweise entschlüsselt und die verschiedenen Sensorwerte pro gesendetem Byteblock zur Verfügung gestellt. Der Code vom Hersteller bietet eine Callback-Methode, der eine eigene Funktion übergeben werden kann. Im Folgenden wird auf diesen Code vom Hersteller aufgebaut und in einer Klasse `DeviceModel` gekapselt.

4.7.4.2 *Asynchrone Verwaltung der Sensoren*

Das Aufzeichnungssystem implementiert eine asynchrone Architektur zur Verwaltung mehrerer IMU-Sensoren, basierend auf der *asyncio* Bibliothek von Python. Die zentrale Steuerungskomponente in `main.py` erstellt und verwaltet für jeden konfigurierten Sensor eine unabhängige Instanz einer Sensor-Klasse, die jeweils in einem separaten *asyncio* Task ausgeführt wird. Diese Architektur ermöglicht eine quasi parallele Ausführung, bei der jeder Sensor unabhängig von den anderen seine Daten erfassen und verarbeiten kann, ohne dass es zu Blockierungen kommt.

Jede Sensorinstanz durchläuft einen definierten Initialisierungsprozess. Zunächst erfolgt die Geräteerkennung über den `BleakScanner`, der das Bluetooth-Low-Energy (BLE) Protokoll nutzt, um nach den in der Config hinterlegten

Sensoren mit der spezifischen IMU-Adresse zu suchen. Der Suchvorgang implementiert einen Timeout Mechanismus von 10 Sekunden, um nicht blockierend auf nicht erreichbare Geräte zu reagieren. Nach erfolgreicher Identifikation wird eine Bluetooth Verbindung aufgebaut, die durch das `DeviceModel` Objekt gekapselt wird.

Eine Herausforderung besteht in der Fehlerbehandlung über verschiedene Ebenen und Loops hinweg. Auf der untersten Ebene fängt das `DeviceModel` Objekt Bluetooth-spezifische Verbindungsfehler ab und wandelt sie in einheitliche Exceptions um. Die darüberliegende Sensor Instanz verarbeitet diese Fehler. Für die Fehlerbehandlung bei Verbindungsabbrüchen oder Paketverlusten implementiert das System einen Wiederherstellungsmechanismus. Bei Unterbrechungen initiiert es automatisch Wiederherstellungsversuche mit einer exponentiellen Backoff-Strategie (3s, 6s, 12s, ...).

Besondere Aufmerksamkeit erfordert das saubere Beenden des Systems bei einer STRG+C Eingabe des Benutzers. Der Shutdown Prozess ist mehrstufig aufgebaut, um Datenverluste zu vermeiden. Zunächst wird ein globales Stopp Signal an alle Sensor Tasks gesendet, das diese veranlasst, ihre Datenströme geordnet zu beenden. Parallel dazu beginnt ein Timeout Mechanismus, der nach einer Sekunde noch aktive Tasks zwangsweise beendet. Diese mehrstufige Herangehensweise stellt sicher, dass einerseits genügend Zeit für das Abschließen laufender Operationen bleibt, andererseits das System zuverlässig terminiert. Jede Sensor Instanz verfügt über ihren eigenen Zustandsautomaten, der die aktuelle Phase des Shutdown Prozesses verwaltet. Der Hauptevent Loop koordiniert diese einzelnen Zustandsmaschinen und sammelt die Ergebnisse, bevor er das Programm endgültig beendet. Dieser Ansatz ermöglicht es, selbst bei komplexen Fehlerszenarien die Systemkonsistenz zu wahren und Datenverluste zu minimieren.

4.7.4.3 *Datenschreibprozess*

Der Datenschreibprozess wurde als eigenständige Komponente implementiert, die speziell für die Anforderungen in einem Umfeld mit asynchronen Bluetooth Sensoren ausgelegt ist. Die Klasse `ParquetDataWriter` übernimmt die Verwaltung des gesamten Schreibvorgangs und gewährleistet eine effiziente und zuverlässige Speicherung der Sensordaten.

Das System verwendet das Parquet Dateiformat aufgrund seiner technischen Eigenschaften, die speziell für die Speicherung von Sensordaten vorteilhaft sind. Im Gegensatz zu textbasierten Formaten wie CSV speichert Parquet die Daten in einem kompakten binären Format, was zu deutlich kleineren Dateigrößen führt. Für jede Körperposition wird eine separate Datei angelegt. Die Speicherung erfolgt in einem automatisch erstellten Verzeichnis, dessen Name den Zeitstempel der Messung im Format YYYY-MM-DD_HH-MM-SS enthält. Optional kann über Kommandozeilenparameter ein beschreibender Zusatz wie z.B. die Probanden-ID hinzugefügt werden. Folgende Sensorwerte werden gespeichert:

- Zeitstempel
- Beschleunigung (AccX, AccY, AccZ)
- Gyroskop (AngX, AngY, AngZ)
- Magnetometer (HX, HY, HZ)
- Quaternionen (Q0, Q1, Q2, Q3)

Ein zentrales Element des Schreibprozesses ist der mehrstufige Puffermechanismus. Die eingehenden Sensordaten werden zunächst in einem ringbufferbasierten Speicher (`collections.deque`) zwischengelagert. Dieser Puffer dient mehreren Zwecken: Er reduziert die Schreibzugriffe auf das Dateisystem, aggregiert die Daten zu effizienten Schreibblöcken und puffert kurzfristige Systemlastspitzen ab. Der Puffer wird erst in die Parquet Datei geschrieben, wenn eine gewisse Anzahl an Einträgen überschritten wird. Dieser Wert kann in der Config angepasst werden und beträgt standardmäßig 1000 Einträge.

Besondere Sorgfalt wurde auf die Behandlung von Systemabbrüchen und Verbindungsproblemen gelegt. Vor jedem erneuten Verbindungsaufbau wird überprüft, ob noch ungeschriebene Daten im Puffer vorhanden sind. In diesem Fall erfolgt ein synchroner Schreibvorgang, der sicherstellt, dass alle Daten persistent gespeichert werden, bevor eine neue Verbindung aufgebaut wird. Dieser Mechanismus verhindert Datenverluste bei unerwarteten Unterbrechungen. Des Weiteren gibt es einen finalen Flush des Puffers im Destruktor, regelmäßige automatische Sicherungspunkte und eine Fehlerbehandlung bei Schreiboperationen. Diese Maßnahmen stellen sicher, dass selbst bei unerwarteten Programmabbrüchen maximal ein Pufferinhalt (standardmäßig 1000 Werte) verloren gehen kann.

4.7.4.4 *Logging*

Ein Logging der wichtigsten Ereignisse während der Ausführung des Programms wurde implementiert. Dazu gehören die erfolgreiche Verbindung zu den Sensoren, der Start des Schreibprozesses, Verbindungsabbrüche und der Abbruch des Programms durch den Benutzer. Der Log wird während der Ausführung des Programms im Terminal angezeigt, als auch als `.log` Datei gespeichert.

Das Logging im Terminal gibt dem Benutzer wichtige Informationen während der Versuchsdurchführung. Es dauert einen Moment, bis alle fünf Sensoren erfolgreich verbunden sind und der Schreibprozess gestartet ist. Nach der Rückmeldung, dass alle Sensoren verbunden sind, kann der Benutzer dem Probanden das Signal zum Starten geben. Des Weiteren ermöglicht das Logging im Terminal, auf unvorhersehbare Ereignisse zu reagieren. So kann z.B. bei einem Verbindungsabbruch während der Aufzeichnung der Versuch mit dem Probanden gegebenenfalls wiederholt werden.

Alle Ereignisse des Logs werden auch in einer Logdatei gespeichert. Diese wird in demselben Ordner abgelegt wie die Sensoraufzeichnungen. Dadurch

kann auch nach der Messung die Ereignisse nachvollzogen werden. Bei z.B. Anomalien in den Sensordaten kann verifiziert werden, ob es in dem Zeitraum einen Verbindungsabbruch des Sensors gab.

Um die Logs filtern zu können, wurden die Ereignisse in verschiedene Log-Level unterteilt. Die wichtigsten Ereignisse wie erfolgreiche Verbindungen und Abbrüche sind mit `SUCCESS`, `WARNING` und `ERROR` gekennzeichnet. Feinere Logs mit dem Level `DEBUG` wurden für das Starten und Verlassen diverser *asyncio* Schleifen verwendet, dies war hilfreich für das Debugging während der Entwicklung.

4.7.4.5 *Konfiguration und Validation*

Die wichtigsten Parameter und Einstellungen wurden in einer `config.py` Datei verwaltet. Dabei wurde die Python-Bibliothek *Pydantic* verwendet, um ein Datenobjekt zu definieren und die Felder zu validieren.

Die fünf zu verbindenden Sensoren werden in der Config als Sensorgruppe definiert und deren UUIDs hinterlegt. Dadurch muss der Benutzer keine Adressen zum Verbinden eingeben und das Programm sucht automatisch die definierten IMU-Sensoren. Innerhalb der Sensorgruppe wird jedem Sensor eine Position am Körper zugeordnet. Die Positionen sind durch Enums definiert, wie z.B. `LEFT_ARM`. Es können mehrere Sensorgruppen definiert werden, also eine Ansammlung an UUIDs mit jeweiliger Position. Der Sensorgruppe wird ein Name zugewiesen. Das wurde verwendet, um während des Versuchs gleichzeitig zwei Hüftsensoren an unterschiedlichen Personen zu verwenden und dabei durchrotieren zu können. Des Weiteren sind in der Config der Ordnername, in dem die Messungen gespeichert werden, und die Größe des Puffers des Schreibprozess festgehalten.

Mittels *Pydantic* werden mehrere Parameter in der Config auf ihre Richtigkeit validiert. Die Validierung erfolgt zum Zeitpunkt der Instanzierung des Config Objekts, also beim Start des Programms und vor der Verbindung zu den Sensoren. Bei Fehlern in der Config wird der Benutzer auf diese also vor dem Start der eigentlichen Aufzeichnung informiert.

Zum einen wird die UUID pro Sensor auf ihre Richtigkeit validiert. Des Weiteren wird überprüft, dass innerhalb einer Sensorgruppe jede Körperposition nur einmalig definiert ist. Das ist wichtig, um Fehler und Verwechslungen in den Messungen zu vermeiden. Die Daten jedes Sensors werden in einer eigenen Datei, benannt nach der Körperposition, gespeichert. Doppelte Zuweisungen eines Körperteils sind für die Nachvollziehbarkeit kritisch.

4.7.5 *Langzeittest*

Vor der Versuchsdurchführung mit Probanden wurde mit sechs Sensoren ein Langzeittest durchgeführt. Ziel war es, die Zuverlässigkeit der Sensoren herauszufinden. Dabei wurde auf Verbindungsabbrüche, Drifts in den Messwerten und die Akkulaufzeit geachtet. 6 Sensoren wurden auf einem Schreibtisch nebeneinander abgelegt und eingeschaltet. Die Dauer der Mes-

sung betrug 4,5 Stunden bei einer Übertragungsrate von 200 Hz. Während der Messung wurden die Sensoren nicht bewegt.




Abbildung 4.6: Gleitender Durchschnitt (Fenster 5 min) der Beschleunigung (links) und des Gyroskops (rechts) von 6 Sensoren über eine Zeit von 4,5 h

In Abbildung 4.6 lassen sich die Beschleunigungswerte erkennen. Die Sensoren starten auf unterschiedlichen Niveaus, sind aber während der gesamten Messung stabil. Nur in Z-Richtung lässt sich ein leichter Drift nach unten erkennen. Obwohl die Sensoren nicht bewegt wurden, sind in Y-Richtung Ausschläge nach unten. Diese können sich dadurch erklären, dass die Unterlage während der Messung berührt wurde und es zu Schwingungen gekommen sein kann. Des Weiteren gibt es in Z-Richtung bei einem einzelnen Sensor einen ungewöhnlichen Ausschlag nach unten.

In Abbildung 4.6 sind die Winkeländerungen des Gyroskops abgebildet. Da die Sensoren nicht bewegt wurden, ist hier auf allen Achsen ein Wert von Null zu erwarten. Auf allen Achsen sind im Laufe der Zeit Winkeländerungen zu erkennen, diese bewegen sich aber in einem sehr geringen Wertebereich.

Die absoluten Winkel sind in Abbildung 4.7 dargestellt und starten pro Sensor auf unterschiedlichen Werten. Dies ist zu erwarten, denn je nach Sensorposition und Kalibrierung ist der Winkel initial unterschiedlich. Die Winkelpositionen sind stabil, es lässt sich kein Drift erkennen. Es gibt vereinzelte Ausschläge, die aber bei jedem Sensor gleich auftreten. Auffällig ist der Winkel in Z-Richtung bei einem Sensor. Hier fällt dieser plötzlich ab und gibt einen negativen Wert danach stabil aus.

Die Quaternionen in Abbildung 4.7 starten auf unterschiedlichen Niveaus und sind weitgehend stabil. Lediglich ein Sensor (dargestellt in lila) fällt in allen Dimensionen an einem Zeitpunkt ab.




Abbildung 4.7: Gleitender Durchschnitt (Fenster 5 min) des Winkels (links) und der Quaternionen (rechts) von 6 Sensoren über eine Zeit von 4,5 h

5. METHODIK

5.1 DATENVORVERARBEITUNG

5.1.1 *Erstellung der Zielvariable der Ermüdung*

Zur Quantifizierung des Ermüdungszustands wird eine einheitliche Zielvariable konstruiert, die subjektive und objektive Messgrößen aus der Studie kombiniert. Es wird ein Ermüdungsindex erstellt, der die subjektiven Einschätzungen (auf der ROF und ASS Skala) mit objektiven Kraftparametern (Maximalkraft und RFD_{200ms}) zu einem vorhersagbaren Gesamtwert vereint. Die Mean Propulsive Velocity (MPV) wird als sinnvolle Kraftmessung verworfen.

Die Datenvorverarbeitung beginnt mit der Extraktion und Aufbereitung der Maximalkraftdaten, gefolgt von der Berechnung des RFD aus den Sensordaten des Dynamometers. Zusätzlich werden die IMU-Sensordaten der Klimmzugbewegungen verarbeitet, um die Mean Propulsive Velocity (MPV) als weiteren Leistungsindikator zu erfassen, die jedoch für die weitere Betrachtung verworfen wird.

Die standardisierten Einzelparameter werden durch eine gewichtete Linearkombination zu einem einheitlichen Ermüdungsindex zusammengeführt, wobei subjektive und objektive Komponenten gleichgewichtet berücksichtigt werden. Eine anschließende Min-Max-Normalisierung transformiert den Index in den Wertebereich $[0, 1]$, wobei höhere Werte eine stärkere Ermüdung bedeuten.

5.1.1.1 *Datenvorverarbeitung der Maximalkraft*

Die Ergebnisse der Fingermaximalkraftmessung (F_{max}) werden aus der App des Dynamometers als CSV-Datei exportiert. Eine weitere Verarbeitung der Daten erfolgte nicht, diese waren aus der App bereits vollständig. Die extrahierten Maximalkraftwerte pro Probanden sind in Abbildung 5.1 zu sehen. Es lässt sich ein Kraftabfall im Verlauf der Versuchsmessungen erkennen.




Abbildung 5.1: Die gemessene Maximalkraft der Probanden getrennt für links (blau) und rechts (rot)

5.1.1.2 Datenvorverarbeitung der RFD

Die App des Dynamometers bietet die RFD als berechnete Größe für $RFD_{20\%-80\%}$ und RFD_{100ms} bereits an. Da nicht dokumentiert ist, wie die App die Metriken berechnet, wurde entschieden, die RFD-Werte selbst aus den Zeitreihen zu berechnen, die ebenfalls als Export angeboten werden. Im Folgenden wird mit den Zeitreihen Kraft (kg) zu Zeit (s) weitergearbeitet.

Für die Berechnung der RFD mit Intervall (z.B. 200 ms) muss ein Startpunkt der Messung definiert werden, ab dem die Steigung bis zu dem definierten Intervall gemessen wird. Der Startpunkt kann nicht fest nach einem Zeitpunkt definiert werden, weil die Probanden zu unterschiedlichen Zeitpunkten mit der Kraftmessung gestartet haben. Auch ein fester Schwellwert an Kraft, der überschritten werden muss, ist nicht verwendbar, weil manche Probanden das Dynamometer vor der eigentlichen Messung bereits leicht belastet haben, wie in Abbildung 5.2 zu erkennen ist.

Stattdessen wird der Beginn der Messung innerhalb der Kraftkurve detektiert, wenn eine Steigung von 10 kg/s überschritten wird. Dadurch ist es nicht relevant, zu welchem Zeitpunkt oder beginnend ab welchem Kraftniveau der Probanden seine Kraftmessung durchgeführt hat.

Die Kraftkurve wird linear interpoliert, damit Kraftwerte auch zwischen den Beobachtungen ermittelt werden können. Das ist relevant für die Intervallberechnung der RFD, die z.B. einen Kraftwert nach 200 ms für die Berechnung benötigt.

Da es unterschiedliche Abwandlungen der RFD-Metrik gibt, wurden folgende unterschiedliche aus den Kraftkurven berechnet und für die weitere Verwendung verglichen. Damit die RFD in der Zielvariable nicht zu hoch gewichtet wird, soll nur eine Abwandlung mit einfließen.

Zeitverlauf des Gewichts nach Proband innerhalb der RFD-Messung




Abbildung 5.2: Kraftkurven der RFD Messungen aller Probanden

- $RFD_{20\%-80\%}$
- $RFD_{95\%}$
- $RFD_{100\%}$
- RFD_{50ms}
- RFD_{100ms}
- RFD_{200ms}

Für das weitere Vorgehen wurde sich für die Metrik RFD_{200ms} entschieden. Im Vergleich zu den anderen Ausprägungen zeigte die RFD_{200ms} pro Probanden die stabilsten fallenden Werte (siehe Abb. 5.3), wohingegen bei anderen Metriken starke Schwankungen vorhanden waren. Außerdem zeigten Levenier und Laffa in ihrer Arbeit, dass RFD_{200ms} die wichtigste Ausprägung für die Kraftmessung als Vergleich der Leistungen beim Klettern darstellt [30].

$$RFD_{200ms} = \frac{F_{\text{Ende}} - F_{\text{Start}}}{0,2 \text{ s}} \quad (5.1)$$




Abbildung 5.3: Berechnete RFD_{200ms} der einzelnen Probanden über mehrere Versuche

5.1.1.3 Datenvorverarbeitung der MPV

Ziel ist es, die Mean Propulsive Velocity (MPV) eines explosiven Klimmzugs nach oben zu messen. Dafür liegen die Daten eines an der Hüfte getragenen IMU-Sensors vor. Im Bezug zur Hüfte des Probanden ist der Klimmzug eine gerade Bewegung senkrecht zum Boden nach oben, weswegen die Beschleunigung in Z-Richtung ermittelt werden muss. Dabei wird aber nicht die Z-Richtung ($AccZ$) lokal vom Sensor betrachtet, sondern die Z-Richtung

des Weltkoordinatensystems. Die Umrechnung geschieht mittels der Quaternionen (mit derselben Formel wie in Kapitel 5.1.2.5). Die Beschleunigung in Z-Richtung wird per Integration in die Geschwindigkeit umgerechnet.

Um die durchschnittliche Geschwindigkeit für die MPV zu berechnen, muss die Phase mit der positiven Geschwindigkeit in der Bewegung ermittelt werden. Bildlich gesehen stellt diese Phase einen Berg oberhalb der X-Achse dar (siehe Abb. 5.4). Der Proband zieht sich hoch und baut eine positive Geschwindigkeit auf. Diese erreicht ihren Höhepunkt in der Mitte der Bewegung und sinkt anschließend ab. Die Geschwindigkeit fällt auf null, wenn der Proband oben angekommen ist.

Um die MPV berechnen zu können, ist es der erste Schritt, Anfang und Ende des Bergs (bildlich für die Kurve) zu markieren. Dies stellte sich als herausfordernd dar, da aufgrund von Anomalien in den Sensordaten nicht immer die positive Bewegungsphase eindeutig zu erkennen war. Teilweise waren mehrere positive Phasen zu erkennen oder keine eindeutige (siehe Abb. 5.5), was die Erkennung erschwerte. Außerdem traten mehrere Fälle auf, bei denen der Sensor eine konstante positive Beschleunigung über mehrere Sekunden gemessen hat, obwohl der Klimmzug nur 1–2s andauerte (siehe Abb. 5.6).

Um in der Geschwindigkeitskurve den Anfang- und Endpunkt der positiven Phase zu detektieren, wurde auf ein manuelles Verfahren verzichtet und stattdessen nach einem automatisierten Verfahren gesucht. Grund dafür ist, dass bei einer automatischen Erkennung Bedingungen definiert werden müssen, die die Anforderungen an einen validen Start- und Endpunkt klar festlegen. Eine manuelle Einteilung wäre subjektiven Entscheidungen unterlegen.






Abbildung 5.7: Automatische Erkennung von Bergstart und -ende in einer Kraftkurve mit adaptiver Basislinie

In Abbildung 5.7 ist eines der getesteten Verfahren zur Erkennung der positiven Komponente dargestellt. Es ist hervorzuheben, dass in diesem Beispiel zwar ein klarer Anstieg zu erkennen ist, dieser aber nicht bei einer Geschwindigkeit von null beginnt. Bereits mehrere Sekunden davor existiert eine unplausible konstante positive Geschwindigkeit.



Das Verfahren in der Abbildung glättet zuerst die rohen Messdaten per Savitzky-Golay-Filter, um Rauschen und Störsignale zu eliminieren und die zugrundeliegende Kurvenform klarer hervortreten zu lassen. Da nicht jeder Berg exakt bei einem y-Wert von null beginnt, wird im nächsten Schritt eine neue, adaptive Basislinie gefunden (dargestellt als blau gestrichelte Linie). Dieser Basiswert wird gefunden, indem die geglättete Kurve nach dem stabilsten, ruhigsten Abschnitt durchsucht wird. Dies geschieht, indem man alle Segmente analysiert und das auswählt, das die geringste Varianz aufweist. Der Medianwert dieses stabilsten Segments dient als Referenzwert und bildet die neue Basislinie. Diese Herangehensweise stellt sicher, dass die Erkennung nicht von einem festen Nullpunkt abhängt, sondern sich an das jeweilige Ausgangsniveau der Daten anpasst. Nun ist es möglich, mit einem Schwellenwert für die Steigung die Start- und Endpunkte aller Abschnitte basierend auf der Basislinie zu identifizieren, die einen Berg darstellen könnten. Aus allen gefundenen Berg-Segmenten wird schließlich das mit der größten Fläche ausgewählt.

Es wurden mehrere automatisierte Verfahren entwickelt, doch keines war anwendbar auf alle beobachteten Daten. Die Anomalien führten dazu, dass keine Methode zuverlässig Start und Ende der Kurve nach oben erkennen konnte. Dadurch konnte der MPV nicht zuverlässig ermittelt werden, weshalb der MPV als Größe für den Kraftverlust verworfen wurde und im weiteren Verlauf nicht mehr betrachtet wird.

5.1.1.4 Kombination und Gewichtung zu einer Zielvariable

Die Kraftmessungen und erfragten Parameter werden zu einer gemeinsamen Zielvariable, dem Ermüdungsindex, kombiniert. Dieser ist später Grundlage der Vorhersage für das Modell. Folgende Variablen werden kombiniert:

- Rating-of-Fatigue (ROF) Skala
- Anstrengungsskala Sport (ASS)
- Maximalkraft (F_{max})
- RFD_{200ms}

Die kombinierte Zielvariable soll die Ermüdung darstellen. Je höher der Wert, desto höher die Ermüdung bei der Versuchsperson. Vor der Kombination müssen die verwendeten Variablen einheitlich ausgerichtet werden. Denn je höher F_{max} und RFD_{200ms} , desto niedriger ist die Ermüdung. Aber je höher die Werte auf den Skalen von ROF und ASS, desto höher ist die Ermüdung. Deswegen wird die Maximalkraft und die RFD vor der Kombination mit -1 multipliziert.

$$y = 0.4 \cdot ROF + 0.1 \cdot ASS + 0.25 \cdot F_{max} + 0.25 \cdot RFD_{200ms} \quad (5.2)$$

Die vier Variablen werden vor dem Kombinieren standardisiert und per Linearkombination zusammengerechnet (siehe Formel 5.2). Somit fließen zu

50% die subjektiven Ermüdungsparameter ROF und ASS ein und zu den anderen 50% die objektiven Ermüdungsparameter Maximalkraft und RFD_{200ms} . Beide Kraftmessungen werden zu jeweils 25% gleichgewichtet. Der ROF wird bei den subjektiven Parametern mit 40% höher bewertet als der ASS, weil der ROF in der Literatur der häufiger verwendete Ermüdungsparameter ist und der ASS bei der Versuchsdurchführung der Probanden schwankt.

$$y_{\text{normalisiert}} = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (5.3)$$

Zur besseren Interpretation wird per Min-Max-Normalisierung der Wertebereich auf das Intervall zwischen 0 und 1 transformiert. Für jeden Probanden soll der erste Versuch als Baseline verwendet und die Ermüdung 0 betragen. Deshalb wird der erste Wert vom Ermüdungsindex auf 0 gesetzt und alle nachfolgenden Versuche dementsprechend verschoben.

5.1.2 Datenvorverarbeitung der IMU-Sensordaten

Die in der Studie gemessenen IMU-Sensordaten der Kletterdurchgänge werden gesichtet und für die weitere Verarbeitung vorbereitet. Es folgt eine Auswahl der gültigen Kletterversuche, eine Bereinigung von Duplikaten und Ausreißern und Berechnungen von weiteren Variablen. Die bereinigten und transformierten Daten werden anschließend für zwei unterschiedliche Modellansätze vorbereitet. Im ersten Ansatz wird ein Feature Engineering durchgeführt, das Merkmale basierend auf den Sensordaten erstellt. Im zweiten Ansatz wird auf den Zeitreihen ein Windowing durchgeführt.

5.1.2.1 Deskriptive Statistik der erhobenen Messwerte

subject	attempt	attempt de facto	duration (seconds)	boulder completed	reason of failure
1	1	1	8	false	failed at start
1	1	2	15	false	only touched second last hold with one hand
1	2	3	15	true	
1	3	4	15	true	
1	4	5	16	true	
2	1	1	28	false	only touched last hold only with one hand
2	2	2	25	true	
2	3	3	25	true	
2	4	4	19	false	only touched second last hold with one hand
3	1	1	19	true	
3	2	2	15	true	
3	3	3	19	true	
3	4	4	13	true	
4	1	1	29	false	only touched last hold only with one hand
4	2	2	15	false	failed middle
4	2	3	30	false	only touched last hold only with one hand
4	3	4	26	false	only touched second last hold with one hand
4	4	5	11	false	failed middle
4	4	6	25	false	only touched last hold only with one hand
5	1	1	19	false	aborted at middle because of instructor
5	1	2	24	true	
5	2	3	24	true	
5	3	4	25	true	
5	4	5	24	true	
6	1	1	22	true	
6	2	2	22	true	
6	3	3	21	true	
6	4	4	21	true	
7	1	1	31	true	
7	2	2	28	true	
7	3	3	30	true	
7	4	4	29	false	only touched last hold with one hand briefly
8	1	1	24	true	
8	2	2	23	true	
8	3	3	23	true	
8	4	4	22	true	
9	1	1	10	false	failed at start
9	1	2	25	true	
9	2	3	26	true	
9	3	4	24	true	
9	4	5	10	false	failed at start
9	4	6	23	true	
10	1	1	29	true	
10	2	2	32	true	
10	3	3	26	true	
10	4	4	24	false	only touched second last hold with one hand

Tabelle 5.1: Übersicht der gemessenen Klettervorgänge pro Proband

Tabelle 5.1 zeigt eine Übersicht der gemessenen Klettervorgänge der Probanden. Pro Proband waren vier Versuche vorgesehen, die jeweils nach den eigenständigen Trainingssessions durchgeführt wurden. Für manche Probanden gibt es mehr als vier Messungen, weil eine Messung wiederholt werden musste, wenn der Boulder nicht absolviert wurde. In der Spalte *boulder completed* ist angegeben, ob der Boulder erfolgreich absolviert wurde. Ein Boulder gilt als absolviert, wenn der letzte Griff des Boulderproblems mit beiden Händen berührt wurde. Die Spalte *reason of failure* beschreibt im Detail,

warum der Boulder nicht absolviert wurde. Dabei gibt es unterschiedliche Grade, wie weit der Proband vom Erledigen des Boulderproblems entfernt war. Manche sind in der Mitte des Kilterboards abgesprungen, während andere Probanden lediglich den letzten Griff nur mit einer Hand berührten. Ein Versuch wurde nur wiederholt, wenn der Boulder nicht erfolgreich geschafft wurde und der Proband dabei nicht weit genug gekommen ist, sodass zu wenig Messdaten aufgenommen wurden.

	Anzahl	Durchschnitt	Std.	Minimum	Maximum	25%-Quantil	50%-Quantil	75%-Quantil
subject	963266	6,44	3,19	1	10	4	6	8
attempt	963266	2,43	1,12	1	4	1	2	3
attempt_real	963266	2,84	1,39	1	6	2	3	4
timestamp	963266	13:52:18.91		10:52:08.00	16:59:59.49	12:33:31.03	13:47:47.03	13:47:47.03
AccX (g)	963266	0,04	0,78	-16,00	16,00	-0,45	0,09	0,52
AccY (g)	963266	-0,05	0,85	-15,99	16,00	-0,79	-0,07	0,63
AccZ (g)	963266	-0,20	0,61	-15,93	16,00	-0,57	-0,17	0,17
AsX (°/s)	963266	0,26	54,38	-1546,75	1371,28	-16,91	0,49	17,64
AsY (°/s)	963266	-0,71	69,33	-1773,87	1520,33	-19,71	-0,85	17,82
AsZ (°/s)	963266	-0,34	68,60	-1357,54	973,27	-15,50	-0,06	15,38
AngX (°)	963266	-3,38	113,72	-180,00	180,00	-96,74	-55,13	105,63
AngY (°)	963266	-2,07	35,66	-89,87	90,18	-29,93	-5,50	26,66
AngZ (°)	963266	14,54	105,03	-180,00	180,00	-94,02	30,72	109,72
HX (μT)	963266	1,34	3,68	-6,53	11,59	-1,69	1,88	3,58
HY (μT)	963266	0,06	2,27	-5,58	6,18	-2,02	0,53	1,96
HZ (μT)	963266	0,81	3,21	-7,39	8,08	-1,38	1,03	3,50
Q0	963266	0,15	0,44	-0,95	0,99	-0,16	0,25	0,49
Q1	963266	0,00	0,53	-0,95	0,99	-0,50	-0,11	0,52
Q2	963266	-0,09	0,55	-0,99	1,00	-0,57	-0,16	0,42
Q3	963266	0,14	0,42	-0,98	0,96	-0,17	0,21	0,47
Q1	957883	0,00	0,53	-0,95	0,99	-0,50	-0,10	0,52
Q2	957883	-0,09	0,55	-0,99	1,00	-0,57	-0,16	0,42
Q3	957883	0,14	0,42	-0,98	0,96	-0,17	0,21	0,47

Tabelle 5.2: Deskriptive Statistik der Sensormesswerte über alle Messungen hinweg

In Tabelle 5.2 ist eine Übersicht der gemessenen Sensorwerte dargestellt. Diese sind für alle erfasste Dimensionen angegeben: Beschleunigung (*AccX*, *AccY*, *AccZ*), Gyroskop (*AngX*, *AngY*, *AngZ*), Magnetometer (*HX*, *HY*, *HZ*) und Quaternionen (*Q0*, *Q1*, *Q2*, *Q3*).

Insgesamt wurden 963266 Messpunkte über alle Probanden und Versuche hinweg aufgenommen.

5.1.2.2 Auswahl der gültigen Versuche und Zeitbereichs

Pro Probanden werden nur vier Versuche für die weitere Verarbeitung betrachtet. Gab es für einen Versuch mehrere Messungen, weil der Versuch wiederholt werden musste (siehe Tabelle 5.1), wird nur der letzte gültige verwendet.

Die aufgezeichneten Sensordaten enthalten auch Zeiträume vor und nach dem eigentlichen Boulder Versuch, da die Messung jeweils etwas früher gestartet und später beendet wurde. Um ausschließlich den relevanten Teil des Bewegungsablaufs zu betrachten, mussten die Daten an den tatsächlichen Start- und Endzeitpunkten des Boulder Versuchs beschnitten werden.

Zur Ermittlung dieser Zeitpunkte wurden die Videoaufnahmen genutzt, die parallel zur Sensordatenerfassung angefertigt wurden. Die Aufnahmen zeigen das Kilterboard zusammen mit einem Zeitstempel im Video. In einem manuellen Arbeitsschritt wurden anhand der Videos der exakte Beginn und das Ende jedes Boulderversuchs für jede Versuchsperson bestimmt. Die zugehörigen Zeitstempel wurden zusammen mit der Probandennummer und dem Versuchsergebnis (ob der Boulder vollständig absolviert wurde oder nicht) in eine separate Tabelle eingetragen.

Die manuelle Erfassung der Start- und Endzeitpunkte in der Tabelle war bewusst als einziger händischer Verarbeitungsschritt vorgesehen. Alle weiteren Schritte, insbesondere das Zuschneiden der Sensordaten auf den relevanten Zeitraum, konnten anschließend automatisiert erfolgen. Durch diese klare Trennung wurde der Aufwand für wiederkehrende Aufgaben minimiert. Gleichzeitig war sichergestellt, dass der gesamte Prozess reproduzierbar blieb: Solange die Tabelle mit Zeitstempeln vorliegt, kann die Datenbeschneidung jederzeit konsistent und ohne erneute manuelle Eingriffe durchgeführt werden.

5.1.2.3 Duplikate in den Zeitstempeln

In den aufgezeichneten Sensordaten treten in den Zeitstempeln Duplikate auf. Wie in Tabelle 5.3 zu erkennen, treten meistens 8 oder 16 gleiche Zeitstempel hintereinander auf. Dabei können die Messwerte pro Zeitstempel (z.B. *AccX*) innerhalb einer Gruppe an Duplikaten unterschiedlich sein. Dementsprechend handelt es sich nicht um Duplikate, bei denen die gesamte Zeile entfernt werden kann.

Anzahl identischer Zeitstempel hintereinander	Vorkommen im Datensatz
8	168310
16	6137
24	124
32	20
40	2
56	2

Tabelle 5.3: Anzahl aller identischer Zeitstempel und Vorkommen im Datensatz

Bei der Messrate von 200 Hz kann vermutet werden, dass das Schreiben des Zeitstempels im Aufnahmeskript nicht genau so schnell war, wie die Geschwindigkeit der eintreffenden Sensordaten. Somit wurden die Sensorwerte zwar korrekt aufgenommen, aber einem falschen Zeitstempel zugewiesen. Da das Aufnahmeskript die Daten asynchron und nicht multithreaded aufgezeichnet hat, ist sichergestellt, dass die Daten in der richtigen Reihenfolge nacheinander gespeichert wurden. D.h., auch mit doppelten Zeitstempel ist ein Messwert mit kleinerem Index früher aufgenommen worden als ein Wert

mit größerem Index. Die chronologische Ordnung ist also trotz gleicher Zeitstempel gegeben.

Zur Korrektur der Duplikate wurde folgende Methode angewendet: Für jede Gruppe von aufeinanderfolgenden Einträgen mit identischem Zeitstempel wurden neue Zeitstempel erzeugt. Diese wurden gleichmäßig zwischen dem ersten Zeitstempel der aktuellen Gruppe und dem ersten Zeitstempel der nächsten Gruppe verteilt. Falls keine nachfolgende Gruppe mehr vorhanden war, wurde ein künstlicher Endzeitpunkt einige Millisekunden später angenommen.




Abbildung 5.8: Oben: Einem Zeitstempel sind mehrere Messwerte für *AccX* zugewiesen. Unten: Nach der Korrektur, die Messwerte sind gleichmäßig zwischen den Zeitstempeln verteilt.

Wie in Abbildung 5.8 zu sehen, ist das Ergebnis eine Zeitreihe mit eindeutigen und gleichmäßig verteilten Zeitstempeln, die die Messungen korrekt abbilden. Vor der Korrektur betrug die Wiederholungsrate der Zeitstempel ca. 20 Hz, nach der Korrektur ca. 200 Hz. Das entspricht der eingestellten Abtastrate der Sensoren und bestätigt die Korrektheit der angewandten Korrektur.

5.1.2.4 Entfernung von Ausreißern




Abbildung 5.9: Werteverteilung für die Beschleunigungswerte $AccX$, $AccY$ und $AccZ$ (Einheiten in g). Beide Werteverteilung vor der Ausreißerentfernung. Bei der rechten Grafik wurden die Ausreißer zur besseren Darstellung ausgeblendet.

Während der Auswertung der Sensordaten traten wiederholt Beschleunigungswerte auf, die außerhalb des zu erwartenden Wertebereichs lagen (siehe Abb. 5.9). Diese hohen Messwerte zeigten sich typischerweise nur sehr kurzfristig und waren häufig auf einzelne oder wenige Zeitpunkte begrenzt. Aufgrund ihrer Höhe und kurzen Dauer wurden sie als unplausibel eingestuft. Es handelte sich hierbei nicht um echte Bewegungsmuster, sondern vermutlich um Messfehler, die durch Hardwareartefakte oder Übertragungsprobleme auftreten können.

Ziel der Datenbereinigung war es, diese kurzzeitigen Ausreißer zuverlässig zu erkennen und zu entfernen, ohne gleichzeitig relevante Bewegungsphasen oder dynamische Spitzenwerte zu verlieren. Entscheidend war dabei, nicht zu hohe oder niedrige Wert zwangsläufig als Ausreißer zu betrachten, sondern erst wenn diese nur für eine kurze Dauer gemessen wurden. Beobachtungen von längerer Dauer sollen hierbei unberührt bleiben.

Die Detektion beruhte auf einem zweistufigen Verfahren. Zunächst wurde geprüft, ob ein Beschleunigungswert in einer der Achsen ($AccX$, $AccY$ oder $AccZ$) einen definierten Schwellwert überschritt. Dabei wurde ein symmetrischer Grenzwert von $> 2g$ bzw. $< -2g$ gewählt. Im zweiten Schritt wurde analysiert, wie lange diese Überschreitung anhielt. Nur wenn diese Schwelle für nicht mehr als vier aufeinanderfolgende Zeitpunkte überschritten wurde, wurde die gesamte Sequenz als Ausreißer markiert. Sequenzen, die länger andauerten, wurden nicht entfernt, da in diesem Fall von einem regulären Bewegungsvorgang ausgegangen werden konnte.

Diese verwendete Schwelle und maximale Sequenzlänge wurden im Vorfeld anhand einer Heatmap bestimmt. In Abbildung 5.10 und Abbildung 5.11 sind verschiedene Kombinationen an Schwellwerten, und für wie viele Zeitstempel hintereinander diese beobachtet wurden, aufgeführt. Anhand




Abbildung 5.10: Anzahl der aufeinanderfolgenden Messungen der Beschleunigung über einen positiven Schwellwert




Abbildung 5.11: Anzahl der aufeinanderfolgenden Messungen der Beschleunigung über einen negativen Schwellwert

dieser Darstellung wurde eine Kombination gewählt, bei der möglichst viele unplausible Messwerte entfernt werden, ohne dabei plausible zu verlieren.

Die Erkennung und Entfernung der Ausreißer erfolgte jeweils gruppiert nach Versuchsperson, Versuchsdurchgang und einzelner Sensor am Körper, sodass kontextbedingte Unterschiede berücksichtigt wurden.

5.1.2.5 Umrechnung der Beschleunigung in globales Koordinatensystem

Die Umrechnung der Beschleunigungsdaten ($AccX, AccY, AccZ$) in ein globales Koordinatensystem ist entscheidend für die Modellentwicklung, da sie eine konsistente und positionsunabhängige Darstellung der Bewegung ermöglicht. Ohne diese Transformation wären die Messwerte direkt an die Ausrichtung des Sensors gebunden, was eine genaue Analyse von Bewegungen wie Geschwindigkeit und Position im Raum erschweren würde. Im Folgenden werden die Werte $AccX_{world}, AccY_{world}, AccZ_{world}$ berechnet.

Die Umrechnung von Beschleunigungsmessungen von einem lokalen Koordinatensystem in ein globales Weltkoordinatensystem erfolgt mithilfe von Quaternionen (siehe Kapitel 2.3.2). Der Prozess beginnt mit der Extraktion der Quaternionen $q = (q_x, q_y, q_z, q_w)$ und den zugehörigen Beschleunigungsvektoren $\vec{a}_{body} = (AccX, AccY, AccZ)^T$ aus den Sensordaten.

Zunächst wird die Norm jedes Quaternionen berechnet, um sicherzustellen, dass es gültig ist:

$$||q|| = \sqrt{q_x^2 + q_y^2 + q_z^2 + q_w^2}$$

Wenn die Norm eines Quaternionen unter einem sehr kleinen Schwellenwert ($\epsilon = 10^{-6}$) liegt, wird angenommen, dass es sich um eine ungültige Rotation handelt. In diesem Fall wird der Beschleunigungsvektor nicht rotiert und bleibt unverändert.

Für alle gültigen Quaternionen wird eine Rotation durchgeführt. Die Quaternionen werden zur Erstellung eines Rotationsoperators verwendet, der die Orientierung des Körpers im Raum beschreibt. Die Transformation des Beschleunigungsvektors $\vec{a}_{body}$ in den globalen Beschleunigungsvektor $\vec{a}_{global}$ erfolgt dann durch die Anwendung dieses Rotationsoperators:

$$\vec{a}_{global} = R(q) \cdot \vec{a}_{body}$$

Hierbei ist $R(q)$ die Rotationsmatrix, die aus dem Quaternion q abgeleitet wird.

Nachdem alle gültigen Vektoren transformiert und die ungültigen Vektoren unverändert übernommen wurden, wird der globale Beschleunigungsvektor $\vec{a}_{global} = (AccX_{world}, AccY_{world}, AccZ_{world})^T$ gebildet.

Abschließend wird der Einfluss der Erdanziehung von der vertikalen Komponente des globalen Beschleunigungsvektors subtrahiert. Da die Beschleunigung der Erdanziehungskraft konstant bei $1g$ liegt, wird dieser Wert von der Z-Achse korrigiert, um die reine translatorische Beschleunigung zu erhalten:

$$AccZ'_{world} = AccZ_{world} - 1$$

Die resultierenden Vektoren stellen die globale Beschleunigung dar.

5.1.2.6 Feature Engineering

Um das im nachfolgenden Kapitel 5.2.2 beschriebene, Feature-basierte Modell zu trainieren, ist es erforderlich, aus den Rohdaten der Zeitreihen relevante Features zu berechnen. Für die Aufbereitung der Sensordaten wurde ein automatisiertes Feature Engineering mit Hilfe des Python-Pakets *tsfresh* [10] durchgeführt. Dabei wurde die Parameterauswahl *EfficientFCParameters* verwendet, die eine ausgewogene Auswahl an 73 Merkmalen berechnet und dabei auf eine effiziente Laufzeit optimiert ist. Durch diesen Ansatz konnten ohne manuelle Auswahl sowohl statistische als auch zeitreihenbasierte Kennwerte aus den Rohdaten generiert werden. Zu den erfassten Merkmalen zählen unter anderem grundlegende statistische Größen wie Mittelwert, Varianz oder Quantile, ebenso wie komplexere Charakteristika der Zeitreihe, beispielsweise Autokorrelationskoeffizienten, Fourier-Transformationskomponenten oder Energien in bestimmten Frequenzbereichen. Auf diese Weise entstand eine Vielzahl an Features, die sowohl die Verteilungseigenschaften der Daten als auch deren zeitliche Dynamik abbilden.

Die Berechnung der Features erfolgt für jeden IMU-Sensor einzeln (linker Arm, Hüfte, etc.) und pro Sensor für 12 erfasste Zeitreihen (*AccX*, *AccY*, *AccZ*, *AsX*, *AsY*, *AsZ*, *AngX*, *AngY*, *AngZ*, *AccX_{world}*, *AccY_{world}*, *AccZ_{world}*). Somit gibt es pro Proband und pro Versuch ein Feature für ein gegebenes Körperteil und eine Kenngröße (z.B. *left_arm_AccZ_abs_energy*).

Zusätzlich zu den aus den einzelnen Sensorachsen extrahierten Merkmalen wurden weitere Features berechnet, die die Relationen zwischen den verschiedenen am Körper angebrachten Sensoren abbilden. Hierzu wurden für jede mögliche Kombination zweier Körperteile die Differenzen zentraler statistischer Kennwerte wie Mittelwert, Standardabweichung und Maximum bestimmt. Ergänzend wurde das Verhältnis dieser Größen berechnet, um relative Unterschiede zwischen den Sensoren zu erfassen. Diese relationalen Features ermöglichen es, nicht nur die Bewegungscharakteristika einzelner Sensorpositionen zu berücksichtigen, sondern auch systematisch Unterschiede und Abhängigkeiten zwischen verschiedenen Körperregionen zu modellieren, was insbesondere für die Erkennung komplexer Bewegungsmuster von Bedeutung ist.

Für das Modell wird einmal die Parameterauswahl *EfficientFCParameters* mit und ohne das Hinzufügen der Kombination der Körperteile verwendet und der verringerte Parametersatz *MinimalFCParameters*.

5.1.2.7 Verkettung und Windowing

Für das Rohdaten-basierte Modell werden für jeden Probanden die Versuche hintereinander verkettet. Dadurch entstehen für jeden Probanden unterschiedlich lange Beobachtungen (siehe Abb. 5.12).




Abbildung 5.12: Unterschiedlich lange Zeitreihen pro Proband nach Verkettung der Versuche

Anschließend wird das Verfahren des Windowing angewendet. Dieses Vorgehen war notwendig, da die vorliegenden Zeitreihen eine unterschiedliche Länge aufweisen, einige Modelle aber pro Feature gleich lange Beobachtungen erwarten. Darüber hinaus waren die Zeitreihen in ihrer ursprünglichen Form sehr lang, was zu einer hohen Komplexität und damit zu einem hohen Rechenaufwand geführt hätte. Durch die Unterteilung der Daten in kleinere Abschnitte konnten diese Probleme vermieden werden und die Daten wurden in eine Form gebracht, die sich besser für die Modellierung eignet.




Abbildung 5.13: Überlappende Segmente für eine gegebene Segmentlänge und Fensterschritt

Das Windowing basiert auf zwei zentralen Parametern, der Segmentlänge und dem Fensterschritt (siehe Abb. 5.13). Die Segmentlänge legt fest, wie viele Zeitpunkte in einem Abschnitt enthalten sind. Der Fensterschritt bestimmt, an welcher Position das nächste Fenster beginnt. Wenn die Segmentlänge und der Fensterschritt gleich groß sind, resultiert dies in nicht überlappenden Segmenten. Jedes Segment beginnt unmittelbar nach dem Ende

des vorherigen Segments, sodass die Daten in eine Reihe von diskreten, aufeinanderfolgenden Segmenten ohne Überlappung aufgeteilt werden.

Wenn der Fensterschritt kleiner als die Segmentlänge ist, dann überlappen sich die Fenster. Die Überlappung stellt sicher, dass Informationen an den Segmenträndern nicht verloren gehen, indem jeder Datenpunkt in mehreren Segmenten verarbeitet wird. Dies erhöht die Robustheit des Modells gegenüber Verzerrungen, die durch die Segmentierung entstehen können und die Übergänge in den Daten können besser modelliert werden.

Die Segmentierung der Zeitreihen erfordert eine entsprechende Anpassung der Zielvariable y . Pro Versuch eines Probanden liegt nur ein Ermüdungszustand als y -Label vor. Wenn die Zeitreihe des Versuchs in mehrere Segmente unterteilt wird, muss jedem Segment weiterhin ein y -Label zugeordnet werden. Als erster Ansatz wird dafür bei n -Segmenten das y -Label n -mal repliziert.

Die direkte Kopie des Labels für jedes Segment würde jedoch zu einer redundanten und möglicherweise irreführenden Datendarstellung führen, da das Modell bei jedem Segment den gleichen Zielwert zugeordnet bekommt. Mit der Annahme, dass die Ermüdung zwischen den Versuchen kontinuierlich steigt und um eine schrittweise Veränderung des Labels zu ermöglichen, wird eine Interpolation des y -Labels verwendet. Durch diese Anpassung wird das Modell trainiert, nicht nur den finalen Zustand, sondern auch die Entwicklung des Zustands innerhalb der Zeitreihe zu erkennen und vorherzusagen.

Die Segmentierung wird auf die 12 erfassten Zeitreihen $AccX$, $AccY$, $AccZ$, AsX , AsY , AsZ , $AngX$, $AngY$, $AngZ$, $AccX_{world}$, $AccY_{world}$, $AccZ_{world}$ angewendet. Bei einer Segmentlänge von 800 und einem Fensterschritt von 200 würde damit eine Datenmatrix in der Dimension $(4425, 800, 12)$ entstehen. Der dazugehörige Zielvektor y hat die Dimension $(4425,)$.

Für das Modelltraining werden unterschiedliche Parameter für die Segmentlänge und Fensterschritt ausprobiert.

5.2 MODELLENTWICKLUNG

Dieser Abschnitt beschreibt die Entwicklung und den Vergleich verschiedener Modellansätze, die zur Vorhersage der Ermüdung basierend auf IMU-Sensordaten eingesetzt werden.

Zunächst werden die Baseline-Modelle eingeführt, die als Maßstab dienen. Die Performance der nachfolgenden, komplexeren Modelle, muss die Ergebnisse der Baseline-Modelle übertreffen, um deren Nützlichkeit zu belegen.

Anschließend werden zwei unterschiedliche Modellarchitekturen entwickelt und analysiert. Zum einen das Feature-basierte Modell mit XGBoost, das auf einem traditionellen maschinellen Lernansatz beruht. Hierbei werden die im vorherigen Abschnitt erstellten Features verwendet. Der XGBoost Algorithmus nutzt diese vorbereiteten Features, um Vorhersagen über den Ermüdungsgrad zu treffen.

Als zweite Architektur wird ein Rohdaten-basiertes Modell mit Attention entwickelt. Dieses Deep-Learning-Modell arbeitet ohne Features direkt mit den IMU-Sensordaten, die im vorherigen Kapitel per Windowing vorbereitet wurden. Ein zentrales Element dieser Architektur ist der Aufmerksamkeitsmechanismus. Dieser ermöglicht es dem Modell, die für die Vorhersage der Ermüdung relevantesten Bewegungsmuster in den Zeitreihendaten selbstständig zu identifizieren und zu gewichten, wodurch die Notwendigkeit einer manuellen Merkmalsextraktion entfällt.

5.2.1 Baseline-Modelle

Baseline-Modelle dienen als Referenz, um die Leistung eines Vorhersagemodells einzuschätzen. Sie sind einfache Modelle, die keine komplexen Zusammenhänge lernen, und zeigen, wie gut ein Modell mindestens abschneiden sollte. In dieser Arbeit werden zwei Baseline-Modelle verwendet.

Das erste Modell ist ein zufälliges Baseline-Modell, das für jede Vorhersage einen Wert zwischen 0 und 1 gleichverteilt zieht. Die Vorhersagen sind unabhängig. Um die Wiederholbarkeit zu gewährleisten, wird bei dem Zufallszahlengenerators ein Seed festgesetzt.

$$\hat{y}_{\text{random}}^{(i)} \stackrel{\text{i.i.d.}}{\sim} \mathcal{U}(0, 1), \quad i = 1, \dots, n \quad (5.4)$$

Das zweite Modell ist ein linear ansteigendes Modell, das die Vorhersagen gleichmäßig zwischen 0 und 1 verteilt. Dieses Modell basiert auf der Annahme, dass die Ermüdung y mit zunehmender Versuchszahl steigt.

$$\hat{y}_{\text{increase}}^{(i)} = \frac{i - 1}{n - 1}, \quad i = 1, \dots, n \quad (5.5)$$

5.2.2 Feature-basiertes XGBoost-Modell

Für die Modellierung der zuvor extrahierten Features (Kapitel 5.1.2.6) wird ein XGBoost Regressor eingesetzt. Da die verschiedenen Feature Dimensionen unterschiedliche Wertebereiche haben, erfolgte zunächst eine Standardisierung, bei der die Daten auf einen Mittelwert von 0 und eine Standardabweichung von 1 transformiert wurden. Dadurch wurde sichergestellt, dass kein Feature das Modell aufgrund der Skalierung unverhältnismäßig stark beeinflusst.

Die hohe Anzahl an Features des Datensatzes (ca. 40 000) stellt eine Herausforderung dar. Die Hauptgefahr ist das Overfitting, bei dem das Modell lernt, die Trainingsdaten perfekt abzubilden. Dies beeinträchtigt die Fähigkeit des Modells, auf unbekannte Daten zu generalisieren. Um diesem Problem zu begegnen, wurden die Parameter des XGBoost-Modells gezielt angepasst, um seine Komplexität zu reduzieren und es robuster zu gestalten.

Eine vollständige Auflistung der Hyperparameter ist im Appendix A.2.1 zu finden

Um die hohe Anzahl an Merkmalen zu bewältigen, wurde beim Training nicht das gesamte Datenset verwendet, sondern stattdessen wurde ein Daten- und Feature-Sampling eingesetzt. Anstatt alle Datenpunkte zu nutzen, wurde nur eine zufällige Auswahl von 80% der Daten für jeden Baum verwendet, was die Varianz des Modells reduziert. Noch wichtiger ist die Maßnahme, bei der die Bäume gezwungen wurden, nur mit einer zufälligen Untergruppe von Merkmalen zu arbeiten. Für jeden Baum wurden nur 50% der Features berücksichtigt, und auf jeder Ebene eines Baumes wurde diese Auswahl auf 30% reduziert. Diese Vorgehensweise hat den Effekt, dass das Modell gezwungen wird, robustere Muster zu finden, die nicht von einem einzigen Set von Merkmalen abhängen.

Zusätzlich wurden L1- und L2-Regularisierung angewendet, um die Komplexität des Modells zu kontrollieren. Diese Techniken bestrafen zu große Koeffizienten und verhindern, dass einzelne Merkmale eine übermäßige Bedeutung erhalten. Insbesondere die L1-Regularisierung ist in diesem Kontext wertvoll, da sie dazu neigt, die Bedeutung von irrelevanten Merkmalen auf 0 zu setzen. Dies führt effektiv zu einer automatischen Feature-Selektion und reduziert die Anzahl der genutzten Features auf natürliche Weise. Um die Bäume selbst weniger komplex zu machen, wurde ihre Tiefe auf drei Ebenen begrenzt. In Verbindung mit einer sehr langsamen Lernrate konnte das Modell die Fehler schrittweise und gezielt korrigieren, was die Generalisierungsfähigkeit des Modells weiter verbesserte.

5.2.3 Rohdaten-basiertes Attention-Modell

Für das Rohdaten-basierte Modell wird ein hybrider Ansatz gewählt, der ein CNN und eine Multi-Head-Attention mit einer Masked-Self-Attention kombiniert. Diese hybride Architektur ist für die Verarbeitung von Zeitreihendaten geeignet und kombiniert die Stärken von CNNs und Aufmerksamkeitsmechanismen, um sowohl lokale Muster als auch globale Abhängigkeiten innerhalb der Daten zu erfassen [19, 35]. Das Modell verwendet die in Kapitel 5.1.2.7 beschriebenen segmentierten Daten.




Abbildung 5.14: Architektur eines hybriden CNN Multi-Head-Attention-Modells

Das Modell verwendet als Input Daten der Dimension (Segmentlänge, 12). Es werden 12 verschiedene Sensorwerte und damit Zeitreihen, mit der im Windowing Verfahren gewählten Segmentlänge, verarbeitet. Die 12 Features

sind: $AccX$, $AccY$, $AccZ$, AsX , AsY , AsZ , $AngX$, $AngY$, $AngZ$, $AccX_{world}$, $AccY_{world}$ und $AccZ_{world}$.

Die Architektur beginnt mit einer 1D-Faltungsschicht (Conv1D), die 64 Filter mit einer Kernelgröße von 5 anwendet. Diese Schicht ist darauf ausgelegt, lokale Muster und Merkmale in der Eingangszeitreihe zu extrahieren. Durch die Verwendung des Parameters `padding='causal'` in TensorFlow stellt die Faltung sicher, dass die Ausgabe zu einem bestimmten Zeitpunkt ausschließlich von den aktuellen und vergangenen Datenpunkten abhängt, was für Zeitreihenanalysen wichtig ist. Die nachfolgende LayerNormalization-Schicht stabilisiert die Ausgabe der Faltungsschicht, was zu einer schnelleren und stabileren Konvergenz während des Trainings beiträgt.

Ein wichtiger Bestandteil der Architektur ist die Masked-Multi-Head-Self-Attention. Sie ist mit 4 Köpfen (`num_heads=4`) konfiguriert und ermöglicht es dem Modell, die relative Wichtigkeit verschiedener Zeitschritte zueinander zu bestimmen. Im Gegensatz zur lokalen Faltung kann die Aufmerksamkeits-Schicht globale Abhängigkeiten über die gesamte Sequenz hinweg modellieren. Die Masked-Self-Attention anstatt einer herkömmlichen Self-Attention sorgt dafür, dass jeder Aufmerksamkeitskopf nur auf vergangene oder den aktuellen Zeitschritt blickt, was die kausale Natur der Zeitreihe bewahrt. D.h. im Training dürfen nur Zeitschritte zurückblickend in der Vergangenheit betrachtet werden, nicht für die Zukunft. Ein Dropout von 0,2 innerhalb der Aufmerksamkeits-Schicht reduziert das Risiko eines Overfittings.

Anschließend folgt eine GlobalAveragePooling1D Schicht, die die räumliche Dimension der Daten durch Mittelwertbildung über die Zeitachse auf einen einzigen Vektor reduziert. Dieser Schritt fasst die wichtigsten Informationen der gesamten Sequenz zusammen. Eine weitere Dropout-Schicht wird zur Regularisierung verwendet. Die endgültige Ausgabe erfolgt über eine Dense-Schicht mit einem einzelnen Neuron und einer linearen Aktivierungsfunktion, wodurch sich das Modell für die Regressionsaufgaben eignet.

5.3 EVALUATIONSVERFAHREN

5.3.1 *Leave-One-Subject-Out Cross-Validation*

Für die Evaluation der Modelle wird eine Leave-One-Subject-Out Cross-Validation (LOSOCV) verwendet. Dabei wird jeweils ein Proband vollständig als Testdatensatz reserviert, während die Daten der übrigen Probanden zum Training des Modells genutzt werden. Dieser Vorgang wird iterativ für alle zehn Probanden durchgeführt, sodass insgesamt 10 Modelle trainiert werden. Auf diese Weise wird vermieden, dass ein Proband gleichzeitig im Trainings- und im Testdatensatz enthalten ist. Zudem entspricht die Vorgehensweise realistischen Anwendungsbedingungen, da das Modell auf bisher ungesehene Probanden angewendet werden soll [17].

Über alle 10 Modelle wird der Durchschnitt und die Standardabweichung der nachfolgenden Metriken betrachtet.

5.3.2 Metriken

Die Bewertung der Modellgüte erfolgt anhand von zwei Kennzahlen: dem mittleren absoluten Fehler (MAE) und der Spearman-Korrelation.

Der Mean Absolute Error (MAE) quantifiziert die durchschnittliche Abweichung zwischen vorhergesagten und tatsächlichen Werten und ist definiert als

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5.6)$$

wobei y_i den tatsächlichen Wert, $\hat{y}_i$ den vorhergesagten Wert und n die Anzahl der Beobachtungen bezeichnet. Diese Metrik gibt somit Auskunft über die Genauigkeit der Vorhersagen in der Skala der vorhergesagten Größe.

Die Spearman-Korrelation bewertet die Rangkorrelation zwischen Vorhersagen und tatsächlichen Werten. Sie ist definiert als

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (5.7)$$

wobei n die Anzahl der Beobachtungen und d_i die Differenz der Ränge der i -ten Beobachtung darstellt.

Die Spearman-Korrelation ist als Metrik relevant, wenn die relative Ordnung der Werte entscheidend ist. In den Daten der Studie steigt die Ermüdung in der Regel mit jedem Versuch eines Probanden an. Ein Modell, das zufällige Ermüdungen ohne erkennbare Ordnung vorhersagt, kann einen geringen MAE haben, weil einzelne Vorhersagen zufällig nahe an den tatsächlichen Werten liegen können. Eine konsistente Abbildung der Rangordnung mit höheren Ermüdungen pro Versuch gelingt jedoch nicht, was sich in einer niedrigen Spearman-Korrelation widerspiegelt. Ein Modell, das diese Tendenz korrekt erfasst, erreicht eine hohe Rangkorrelation, auch wenn die exakten Werte nicht in allen Fällen präzise vorhergesagt werden.

Ein wichtiger Aspekt ist die Signifikanz (p -Wert) der Korrelation, welche angibt, mit welcher Wahrscheinlichkeit die beobachtete Korrelation ρ zufällig aufgetreten ist. Die Korrelation wird typischerweise als statistisch signifikant erachtet, wenn $p < 0,05$ ist, was bedeutet, dass die Wahrscheinlichkeit, diesen oder einen stärkeren Zusammenhang zufällig zu beobachten, gering ist. Ist $p \geq 0,05$, gilt die Korrelation in der Regel als nicht signifikant. Nur wenn die Korrelation statistisch signifikant ist, kann davon ausgegangen werden, dass ein tatsächlicher monotoner Zusammenhang zwischen den Vorhersagen und den tatsächlichen Werten besteht.

Die gemeinsame Betrachtung von MAE und Spearman-Korrelation gewährleistet daher eine umfassende Bewertung der Modelle. Während der MAE die absolute Genauigkeit der Vorhersagen abbildet, stellt die Spearman-Korrelation sicher, dass auch die übergeordneten Trends im Datensatz berücksichtigt werden.

6. ERGEBNISSE

6.1 DATENSATZ

6.1.1 Sensormessungen

	Anzahl	Durchschnitt	Std.	Minimum	Maximum	25%-Quantil	50%-Quantil	75%-Quantil
subject	957883	6,44	3,19	1	10	4	6	8
attempt	957883	2,43	1,12	1	4	1	2	3
attempt_real	957883	2,84	1,39	1	6	2	3	4
timestamp	957883	13:52:20.43		10:52:08.00	16:59:59.49	12:33:31.19	13:47:47.09	15:11:38.22
AccX (g)	957883	0,03	0,70	-16,00	16,00	-0,45	0,09	0,51
AccY (g)	957883	-0,05	0,81	-14,33	14,26	-0,79	-0,08	0,63
AccZ (g)	957883	-0,20	0,56	-13,71	14,78	-0,57	-0,17	0,16
AccX_world (g)	957883	0,00	0,42	-12,97	17,95	-0,12	0,00	0,11
AccY_world (g)	957883	-0,04	0,39	-16,55	12,66	-0,15	-0,03	0,08
AccZ_world (g)	957883	-0,02	0,45	-14,83	17,97	-0,11	0,00	0,10
AsX (°/s)	957883	0,26	53,22	-1546,75	1371,28	-16,85	0,49	17,58
AsY (°/s)	957883	-0,63	67,70	-1773,87	1520,33	-19,59	-0,85	17,76
AsZ (°/s)	957883	-0,36	67,49	-1357,54	973,27	-15,44	-0,06	15,26
AngX (°)	957883	-3,43	113,78	-180,00	180,00	-96,75	-55,34	105,66
AngY (°)	957883	-2,08	35,65	-89,87	90,18	-29,94	-5,50	26,63
AngZ (°)	957883	14,44	105,07	-180,00	180,00	-94,30	30,66	109,74
HX (μT)	957883	1,33	3,68	-6,53	11,59	-1,70	1,88	3,58
HY (μT)	957883	0,06	2,27	-5,58	6,18	-2,02	0,53	1,96
HZ (μT)	957883	0,82	3,20	-7,39	8,08	-1,38	1,03	3,51
Q0	957883	0,15	0,44	-0,95	0,99	-0,16	0,25	0,49
Q1	957883	0,00	0,53	-0,95	0,99	-0,50	-0,10	0,52
Q2	957883	-0,09	0,55	-0,99	1,00	-0,57	-0,16	0,42
Q3	957883	0,14	0,42	-0,98	0,96	-0,17	0,21	0,47

Tabelle 6.1: Deskriptive Statistik des erstellten Datensatzes der Sensormessungen

Ein zentrales Ergebnis dieser Arbeit ist die Erstellung eines Datensatzes. In Tabelle 6.1 sind die wichtigsten Eigenschaften des Datensatzes dargestellt. Ausreißer wurden entfernt, Fehler in den Zeitstempeln korrigiert und die Beschleunigungen relativ zum Weltkoordinatensystem berechnet. Dieser Datensatz ist geeignet als Grundlage für die Modellierung und für weitere Forschungen.

6.1.2 Ermüdung




Abbildung 6.1: Der Ermüdungsindex aus einer Kombination der Kraftparameter. Je höher der Ermüdungsindex, desto höher die Ermüdung.

Abbildung 6.1 zeigt den berechneten Ermüdungsindex für jeden Probanden. Dieser ist eine Kombination aus objektiven Kraftmessungen und subjektiven Einschätzungen des Probanden. Für jeden Teilnehmer lässt sich, je höher der Versuch, ein Anstieg im Ermüdungsindex erkennen. Das spiegelt auch die fachliche Erwartung der Studie wider, dass mit mehr Wiederholungen die Ermüdung steigt.

6.2 MODELLERGEBNISSE

6.2.1 *Feature-basiertes XGBoost-Modell*6.2.1.1 *Ergebnisse*

Modell	MAE Test		MAE Train		Spearman Korrelation	
	Mittelwert	Std.	Mittelwert	Std.	Mittelwert	Std.
XGBoost mit MinimalFCParameters	0,1935	0,0409	0,1846	0,0043	-0,1200	0,4750
XGBoost mit EfficientFCParameters	0,1937	0,0412	0,1830	0,0042	0,2000	0,5727
XGBoost mit EfficientFCParameters + Körperrelation	0,1931	0,0418	0,1829	0,0041	0,1800	0,5173
Baseline increase	0,2375	0,0809			1,0000	0,0000
Baseline random	0,3202	0,1247			0,0400	0,3980

Tabelle 6.2: Ergebnisse des XGBoost-Modells unterschiedlichen Datensätzen und der Baseline Modelle

Tabelle 6.2 fasst die Performance der XGBoost-Modelle und der beiden Baseline-Modelle zusammen, basierend auf dem Mean Absolute Error (MAE) auf den Test- und Trainingsdaten sowie der Spearman-Korrelation. Die Metriken wurden anhand der Mittelwerte und Standardabweichungen (Std.) über die Leave-One-Subject-Out Cross-Validation der 10 Probanden berechnet. Die Ergebnisse der einzelnen Modelle innerhalb der Kreuzvalidierung sind im Appendix (A.3) aufgeführt.

Wie aus den Daten ersichtlich ist, erzielt das Modell XGBoost mit EfficientFCParameters + Körperrelation mit einem MAE von 0,1931 auf den Testdaten die beste Performance. Dies ist eine leichte Verbesserung gegenüber dem Modell XGBoost nur mit den EfficientFCParameters, das einen MAE von 0,1937 aufweist. Beide Modelle übertreffen das XGBoost mit MinimalFCParameters leicht (MAE von 0,1935) und die beiden Baseline-Modelle deutlich. Der niedrigste MAE auf den Trainingsdaten wird ebenfalls vom Modell XGBoost mit EfficientFCParameters + Körperrelation mit einem Wert von 0,1829 erreicht.

Im Vergleich zu den Baseline-Modellen schneiden alle drei trainierten XGBoost-Modelle signifikant besser ab. Das Baseline-Increase-Modell hat einen MAE von 0,2375 und das Baseline-Random-Modell liegt bei 0,3202.

Bezüglich der Spearman-Korrelation erreicht das Modell XGBoost mit EfficientFCParameters den höchsten mittleren Wert von 0,2, während die anderen XGBoost-Modelle mit 0,12 und 0,18 geringere Werte aufweisen. Das Baseline-Increase-Modell besitzt die höchste Spearman-Korrelation von 1. Über alle Folds der Leave-One-Subject-Out Cross-Validation hinweg ist in der überwiegenden Mehrzahl $p < 0,05$, was auf einen statistisch signifikanten monotonen Zusammenhang zwischen den Vorhersagen und den tatsächlichen Werten hindeutet.

6.2.1.2 *Feature Importance*

Der Importance Gain ist eine metrische Größe zur Bestimmung der Relevanz eines Features in XGBoost, die den durchschnittlichen Informationsgewinn

jedes Features über alle Baumsplits hinweg misst. Sie beschreibt die Verbesserung der Modellleistung, die durch die Verwendung eines bestimmten Features zur Aufteilung der Daten erreicht wird. Ein höherer Importance Gain bedeutet, dass ein Feature einen größeren Beitrag zur Reduzierung des Verlustes der Gesamtvorhersage leistet und somit als wichtiger für das Modell eingestuft wird. Durch die Leave-One-Subject-Out Cross-Validation werden pro Featureset 10 unterschiedliche Modelle trainiert. Im Folgenden wird die Feature Importance jeweils aus dem letzten Fold des Modells dargestellt.

Feature	Importance (gain)
left_leg_AngZ_minimum	0,1784
left_leg_AngZ_absolute_maximum	0,1238
left_arm_AngZ_maximum	0,1196
left_leg_AsX_maximum	0,1111
left_arm_AccY_maximum	0,1046
left_leg_AccZ_variance	0,1035
left_leg_AngX_mean	0,0850
right_arm_AccZ_maximum	0,0741
left_leg_AsX_absolute_maximum	0,0739
left_arm_AccX_world_sum_values	0,0718

Tabelle 6.3: Feature importance des XGBoost-Models mit MinimalFCParameters

Das Modell, das mit einfachen statistischen Merkmalen trainiert wurde, zeigt in Tabelle 6.3 eine Konzentration auf die linke Körperseite. Die wichtigsten Features stammen hierbei vom linken Bein und dem linken Arm. Merkmale wie das Minimum und Maximum sowie die Varianz der Sensordaten haben eine hohe Vorhersagekraft. Diese zeitbasierten Statistiken fassen die grundlegenden Bewegungen dieser Körperteile gut zusammen.

Feature	Importance (gain)
right_leg_AsX_fft_coefficient_attr_real_coeff_7	0,3482
right_leg_AccX_fft_coefficient_attr_imag_coeff_79	0,2600
left_leg_AsX_change_quantiles_f_agg_var_isabs_False_qh_1,0_ql_0,2	0,2242
right_leg_AccZ_world_fft_coefficient_attr_abs_coeff_18	0,2196
right_arm_AccY_fft_coefficient_attr_real_coeff_52	0,2009
hip_AccZ_world_fft_coefficient_attr_real_coeff_79	0,1990
left_arm_AccZ_fft_coefficient_attr_angle_coeff_58	0,1840
hip_AccZ_world_fft_coefficient_attr_imag_coeff_93	0,1803
left_arm_AngZ_longest_strike_below_mean	0,1678
right_arm_AccX_fft_coefficient_attr_angle_coeff_58	0,1258

Tabelle 6.4: Feature importance des XGBoost-Models mit EfficientFCParameters

Bei den beiden umfangreicheren Datensätzen (siehe Tabelle 6.4 und 6.5), dominieren die FFT-Koeffizienten. Diese Koeffizienten sind das Ergebnis einer Fast-Fourier-Transformation, einem mathematischen Verfahren, das ein Zeitreihensignal in seine einzelnen Frequenzanteile zerlegt. Sie zeigen, welche Frequenzen oder Schwingungen im Bewegungssignal besonders stark ausgeprägt sind.

Feature	Importance (gain)
right_leg_AsX_fft_coefficient_attr_real_coeff_7	0,3455
right_arm_AccX_fft_coefficient_attr_abs_coeff_79	0,2715
right_leg_AccX_fft_coefficient_attr_imag_coeff_79	0,2617
left_leg_AsX_change_quantiles_f_agg_var__isabs_False_qh_1,0_ql_0,2	0,2515
left_leg_AccZ_world_fft_coefficient_attr_abs_coeff_74	0,2310
left_arm_AsY_fft_coefficient_attr_real_coeff_97	0,2280
right_arm_AccZ_change_quantiles_f_agg_mean__isabs_False_qh_1,0_ql_0,0	0,2064
hip_AccY_world_fft_coefficient_attr_angle_coeff_17	0,1958
left_arm_AccZ_fft_coefficient_attr_angle_coeff_58	0,1852
left_arm_AngZ_longest_strike_below_mean	0,1689

Tabelle 6.5: Feature importance des XGBoost-Modells mit EfficientFCParameters + Körperrelation

In beiden Modellen führt das rechte Bein die Liste der wichtigsten Features an. Die aus den Beinbewegungen abgeleiteten FFT-Koeffizienten sind die wichtigsten Merkmale, was auf die hohe Relevanz von rhythmischen oder periodischen Mustern hinweist. Obwohl auch Merkmale anderer Körperteile wie des Arms und der Hüfte in den Top 10 vorkommen, sind die Frequenzinformationen der Beine am wichtigsten für die Regression. Dies gilt sowohl für das Modell mit EfficientFCParameters (Tabelle 6.4) als auch für die Variante mit den zusätzlichen Körperrelations-Features (Tabelle 6.5). Außerdem ist dieses Phänomen auch für die anderen Folds der Leave-One-Subject-Out Cross-Validation zu beobachten.

6.2.2 Rohdaten-basiertes Attention-Modell

Modell	Segmentlänge	Fensterschritt	Anzahl Segmente	MAE Test		MAE Train		Spearman Korrelation	
				Mittelwert	Std.	Mittelwert	Std.	Mittelwert	Std.
Attention Modell	200	100	8905	0,1337	0,0265	0,1582	0,0073	0,2461	0,1592
Attention Modell	200	200	4455	0,1359	0,0237	0,1562	0,0078	0,2431	0,1639
Attention Modell	400	100	8885	0,1341	0,0249	0,1567	0,0058	0,2549	0,1952
Attention Modell	400	200	4445	0,1365	0,0246	0,1559	0,0083	0,2276	0,1569
Attention Modell	400	400	2224	0,1357	0,0257	0,1569	0,0089	0,2466	0,1369
Attention Modell	800	100	8845	0,1273	0,0307	0,1545	0,0062	0,3428	0,2763
Attention Modell	800	400	2214	0,1346	0,0262	0,1563	0,0088	0,2552	0,1377
Attention Modell	800	800	1109	0,1360	0,0261	0,1577	0,0098	0,2549	0,1345
Attention Modell	1000	100	8825	0,1232	0,0307	0,1530	0,0073	0,3828	0,2821
Attention Modell	1000	500	1770	0,1352	0,0256	0,1545	0,0092	0,2516	0,1156
Attention Modell	1000	1000	887	0,1354	0,0267	0,1554	0,0089	0,3100	0,1377
Baseline increase	200	100	8905	0,2478	0,0690			1,0000	1,0533
Baseline increase	200	200	4455	0,2478	0,0690			1,0000	0,0993
Baseline increase	400	100	8885	0,2478	0,0690			1,0000	0,0351
Baseline increase	400	200	4445	0,2478	0,0690			1,0000	1,2658
Baseline increase	400	400	2224	0,2478	0,0690			1,0000	0,0993
Baseline increase	800	100	8845	0,2478	0,0690			1,0000	0,0351
Baseline increase	800	400	2214	0,2478	0,0690			1,0000	1,1644
Baseline increase	800	800	1109	0,2478	0,0690			1,0000	0,0351
Baseline increase	1000	100	8825	0,2478	0,0690			1,0000	0,0993
Baseline increase	1000	500	1770	0,2478	0,0690			1,0000	1,0533
Baseline increase	1000	1000	887	0,2478	0,0690			1,0000	0,0497
Baseline random	200	100	8905	0,3362	0,0316			0,0174	0,0318
Baseline random	200	200	4455	0,3362	0,0299			0,0122	0,0500
Baseline random	400	100	8885	0,3359	0,0317			0,0192	0,0322
Baseline random	400	200	4445	0,3365	0,0301			0,0085	0,0501
Baseline random	400	400	2224	0,3383	0,0242			0,0361	0,0340
Baseline random	800	100	8845	0,3359	0,0301			0,0192	0,0501
Baseline random	800	400	2214	0,3390	0,0240			0,0233	0,0409
Baseline random	800	800	1109	0,3405	0,0305			-0,0087	0,1131
Baseline random	1000	100	8825	0,3390	0,0395			0,0022	0,0501
Baseline random	1000	500	1770	0,3341	0,0307			0,0313	0,0792
Baseline random	1000	1000	887	0,3438	0,0395			0,0022	0,1340

Tabelle 6.6: Ergebnisse des Attention-Modells

Tabelle 6.6 zeigt die Ergebnisse der Performance-Analyse für das trainierte Attention-Modell im Vergleich zu den Baseline-Modellen. Die Modelle wurden unter verschiedenen Windowing-Parametern (Segmentlänge, Fensterschritt) evaluiert und die Performance wurde anhand des Mean Absolute Errors (MAE) und der Spearman-Korrelation sowohl auf den Test- als auch auf den Trainingsdaten bewertet.

Alle Variationen des Attention-Modells zeigen eine deutlich überlegene Leistung bezüglich des MAE im Vergleich zu den beiden Baseline-Modellen. Innerhalb der Aufmerksamkeitsmodelle variierte die Leistung je nach den gewählten Parametern. Der niedrigste MAE auf den Testdaten (MAE von 0,1232) wurde mit einer Segmentlänge von 1000 und einem Fensterschritt von 100 erreicht. Diese Parameterauswahl erreicht auch die höchste Spearman-Korrelation der Attention-Modelle von 0,3828.

Die beiden Baseline-Modelle schnitten für den MAE durchweg schlechter ab. Das Baseline-Increase-Modell, das einen konstanten MAE von 0,2478 auf den Testdaten zeigt, liefert konstant die beste Spearman-Korrelation von 1. Das Baseline-Random-Modell schnitt am schlechtesten ab, mit den höchsten MAE-Werten (bis zu 0,3438) und den niedrigsten Spearman-Korrela-

tionswerten auf den Testdaten. Über alle Folds der Leave-One-Subject-Out Cross-Validation hinweg ist in der überwiegenden Mehrzahl $p < 0,05$, was auf einen statistisch signifikanten monotonen Zusammenhang zwischen den Vorhersagen und den tatsächlichen Werten hindeutet.

7. DISKUSSION

7.1 DISKUSSION DER ERGEBNISSE

7.1.1 *Feature-basiertes XGBoost-Modell*

Die Ergebnisse der XGBoost-Modelle zeigen, dass die Wahl der Features einen signifikanten Einfluss auf die Modellleistung hat. Die Unterschiede zwischen dem MAE sowohl auf Trainings- als auch auf Testdaten sind zwischen allen drei Modellen marginal. Doch das Modell mit dem kleinsten Featureset hat deutlich den geringsten Spearman-Koeffizienten und damit die schlechteste Fähigkeit, die Rangordnung der Ermüdung vorhersagen zu können. Das Hinzufügen der Körperrelation als zusätzliches Feature führte zwar zu einer leichten Reduzierung des MAE auf dem Test-Set, dies ist jedoch nicht unbedingt ein Beleg für eine verbesserte Generalisierung.

Die konstant niedrigen MAE-Werte auf den Trainingsdaten im Vergleich zu den Testdaten deuten bei allen drei XGBoost-Modellen auf ein gewisses Maß an Overfitting hin.

Beim MAE schlagen alle drei XGBoost-Modelle die Baseline-Modelle deutlich und in der Spearman-Korrelation das Baseline-Random-Modell. Das Baseline-Increase-Modell sticht mit einer Spearman-Korrelation von 1 heraus. Diese Güte wird von keinem anderen Modell erreicht. Das Baseline-Increase-Modell bildet die Rangordnung perfekt ab, wegen der Modelleigenschaft, die Werte von 0 bis 1 aufsteigend zu verteilen.

Die Ergebnisse deuten darauf hin, dass die Wahl der Merkmale die Herangehensweise des Modells an die Regressionsaufgabe direkt beeinflusst. Das einfachste Modell, das auf grundlegende statistische Werte wie Minima und Maxima der Sensordaten zurückgreift, scheint den Ermüdungszustand primär über die Intensität und den maximalen Ausschlag der Bewegungen zu bewerten. Dies könnte Bewegungen mit hohem Kraftaufwand oder extremen Körperhaltungen widerspiegeln. Im Gegensatz dazu nutzen die Modelle mit umfangreicheren Features die höhere Vorhersagekraft der Frequenzdomäne. Die Dominanz der FFT-Koeffizienten legt nahe, dass die Regression entscheidende Informationen aus der Periodizität und dem Rhythmus der Kletterbewegungen zieht. Die Ermüdung manifestiert sich demnach nicht nur in der Intensität, sondern auch in subtilen Veränderungen der Bewegungsmuster über die Zeit.

Eine wichtige Erkenntnis ist die Konzentration der wichtigsten Features auf die Beinbewegungen, insbesondere das rechte Bein. In allen Modellen haben die Merkmale von den Beinen eine überdurchschnittlich hohe Wichtigkeit. Dies lässt vermuten, dass die Regression zur Vorhersage des Ermüdungszustandes hauptsächlich auf den Beinbewegungen beruht. In der Pra-

xis des Kletterns wird Ermüdung häufig durch nachlassende Stabilität der Beine und eine zunehmende Belastung der Arme kompensiert. Die Sensordaten könnten diese schleichenden Veränderungen in der Beinarbeit erfassen. Die rhythmische Natur von Beinbewegungen, die beim Treten oder Wechseln von Tritten auftritt, scheint besonders relevant zu sein und kann durch die Frequenzmerkmale effektiv erfasst werden.

7.1.2 Rohdaten-basiertes Attention-Modell

Die Ergebnisse der Aufmerksamkeitsmodelle mit den signifikant niedrigeren MAE-Werten im Vergleich zu den Baseline-Modellen zeigen, dass das Aufmerksamkeitsmodell in der Lage ist, die zugrunde liegenden Muster in den Daten zu erfassen.

Interessant ist die Auswirkung der gewählten Windowing-Parameter. Die beste Performance erreicht das Modell mit einer Segmentlänge von 1000 und einem Fensterschritt von 100, also einer sehr starken Überlappung. Dieses Modell hat sowohl den besten MAE-Wert im Test als auch die höchste Spearman-Korrelation von 0,3828 innerhalb der Attention-Modelle. Den zweitbesten MAE-Wert erreicht ebenfalls ein Modell mit geringer Schrittweite (Windowing 800, 100), was auf die Wichtigkeit von großen Überlappungen hinweist.

Durch den kleineren MAE auf den Testdaten im Vergleich zu den Trainingsdaten sind keine Zeichen von Overfitting zu erkennen und die Attention-Modelle zeigen eine gute Regularisierung.

Insgesamt sind die Attention-Modelle dem Baseline-Random-Modell in jeder Hinsicht überlegen. Auch das Baseline-Increase-Modell wird im MAE übertroffen, lediglich die Spearman-Korrelation von 1 wird ähnlich wie beim XGBoost-Modell nicht erreicht. Aber mit einem Wert von 0,3828 zeigt das Modell eine gute Annäherung an die Rangordnung der Ermüdung.

Ungeachtet der Metriken besteht aufgrund der Architektur des Rohdaten-basierten Modells ein Mangel an Interpretierbarkeit. Die komplexe Struktur des tiefen neuronalen Netzes, welche Convolutional Layers und den Attention-Mechanismus umfasst, generiert Vorhersagen durch eine Serie von nicht-linearen Transformationen. Dieser Prozess ist nicht direkt nachvollziehbar. Demzufolge können keine direkten Aufschlüsse darüber gewonnen werden, welche spezifischen Muster oder Wechselwirkungen in den Daten für die erreichten Ergebnisse verantwortlich sind.

7.1.3 Vergleich der Modelle

Insgesamt lässt sich aus den vorliegenden Daten ableiten, dass die entwickelten XGBoost- und Aufmerksamkeitsmodelle eine klare Überlegenheit gegenüber den einfachen Baseline-Ansätzen zur Vorhersage der Kletterermüdung aufweisen. Die Ergebnisse beider Modelltypen zeigen, dass sie in der Lage sind, komplexe Muster in den zugrunde liegenden Daten zu erkennen, die für die Baseline-Modelle nicht zugänglich sind.

Während die XGBoost-Modelle eine solide Performance lieferten, deutet die geringe Verbesserung durch zusätzliche Features darauf hin, dass die bestehenden Merkmale bereits den Großteil der relevanten Informationen enthalten. Bei den Aufmerksamkeitsmodellen ist die Leistungsabhängigkeit von den Windowing-Parametern offensichtlich, was die Notwendigkeit einer sorgfältigen Hyperparameter-Optimierung unterstreicht, um das volle Potenzial dieser Modelle auszuschöpfen.

In Bezug auf die Spearman-Korrelation dominieren alle trainierten Modelle das Baseline-Random-Modell, aber erreichen das Baseline-Increase-Modell mit 1 nicht. Das XGBoost-Modell mit `EfficientFCParameters` nähert sich diesem Wert mit einer Korrelation von 0,2 gut an und zeigt damit eine solide Fähigkeit zur korrekten Rangordnung der Vorhersagen. Auch das Aufmerksamkeitsmodell mit einer Segmentlänge von 1000 und einem Fensterschritt von 100 erreicht mit 0,3828 eine bemerkenswerte Korrelation.

Die Spearman-Korrelation von 1 des Baseline-Modells ist ein Artefakt der Modellarchitektur, die eine einfache aufsteigende Ermüdung annimmt. Dennoch ist die Fähigkeit der komplexen Modelle, eine signifikante Korrelation zu erreichen, ein starker Beleg dafür, dass sie sinnvolle Muster erkennen. Da sie gleichzeitig bei der absoluten Vorhersage (MAE) deutlich überlegen sind, zeigt dies, dass die Modelle die Vorhersage der tatsächlichen Ermüdung beherrschen, während die Baseline-Modelle in dieser Hinsicht versagen. Dies verdeutlicht den Trade-off zwischen der korrekten Rangordnung der Vorhersagen und der genauen Vorhersage des Wertes, wobei die trainierten Modelle in der Gesamtleistung die klaren Sieger sind.

7.2 EINSCHRÄNKUNGEN

7.2.1 Modelle

Die Interpretation der Feature Importance der XGBoost Modelle ist nicht ohne Einschränkungen. Die Gain-Metrik zeigt die relative Bedeutung der Features innerhalb des trainierten Modells, aber nicht ihre absolute Relevanz oder eine direkte kausale Beziehung zum Ermüdungszustand. Auch die automatische Generierung von sehr vielen Features durch die Python-Bibliothek *tsfresh* kann zu einer Überrepräsentation von Frequenzmerkmalen führen. Dies wurde in der Modellierung durch eine starke Regularisierung des XGBoost Modells angegangen, um die relevantesten Merkmale zu finden. Zukünftige Untersuchungen könnten alternative Ansätze wie eine manuelle Feature-Selektion oder Dimensionsreduktion in Betracht ziehen, um die Ergebnisse zu validieren und die Rolle der verschiedenen Merkmale noch klarer herauszuarbeiten.

7.2.2 Studie

Die Hauptbeschränkung der Arbeit liegt in der Größe der Stichprobe. Die Datenerhebung wurde mit zehn Probanden durchgeführt. Diese begrenzte

Teilnehmerzahl resultiert in einem kleinen Datensatz, was die statistische Generalisierbarkeit der Ergebnisse potenziell einschränkt. Insbesondere bei komplexen Deep-Learning-Modellen wie dem Attention-Modell kann eine limitierte Datenbasis die Fähigkeit zur optimalen Erlernung von Muster beeinflussen.

Ein weiterer limitierender Faktor betrifft das Studiendesign: Es wurde keine Kontrollgruppe in die Erhebung einbezogen, die keiner Kletterbelastung unterzogen wurde und somit keine Ermüdung zeigte. Oder Probanden, die trotz wiederholter Versuche durch gute körperliche Leistung wenig, bis keine Ermüdung zeigten. Das Design der Studie sah explizit vor, dass die Ermüdung der Probanden mit steigender Anzahl der absolvierten Versuche zunahm. Dies führte zu einer direkten Korrelation zwischen der Versuchsnummer und dem Grad der Ermüdung in den Trainingsdaten.

Diese starke Korrelation stellte eine Herausforderung für die Modellentwicklung dar, da sie das Risiko des Overfitting auf diese Sequenzabhängigkeit extrem erhöhte. Die Versuchsnummer konnte daher nicht als unabhängiges Feature in die Modelle aufgenommen werden, um eine sinnvolle Generalisierung zu gewährleisten. Selbst ein triviales Regressionsmodell, das lediglich die Versuchsnummer als Feature nutzt, erzielte im MAE bessere Ergebnisse als die komplexen, aufwendig trainierten Modelle. Dies verdeutlicht, dass die Modelle stark dazu neigten, diese einfache sequenzielle Abhängigkeit anstelle der Muster in den Sensordaten zu erlernen. Die komplexen Modelle mussten daher darauf trainiert werden, die Ermüdung ausschließlich aus den Veränderungen der IMU-Daten abzuleiten, was die Schwierigkeit der Modellierungsaufgabe stark erhöhte.

8. FAZIT

8.1 FAZIT

Die vorliegende Masterarbeit hat die Vorhersage von Ermüdung im Klettersport mithilfe von IMU-Sensordaten erfolgreich demonstriert und einen Beitrag zur Methodik geleistet.

Ein Hauptbeitrag der Arbeit liegt in der Generierung eines neuen, studienbasierten Datensatzes unter Verwendung eines eigenentwickelten Multi-Sensor-Aufzeichnungssystems. Im Rahmen einer kontrollierten Studie wurden die Bewegungs- und Ermüdungsdaten von zehn Probanden erfasst. Jeder Teilnehmer absolvierte vier standardisierte Kletterversuche in Folge, was die detaillierte Erfassung der progressiven Ermüdungsentwicklung über die Zeit ermöglichte. Die enge Abstimmung des Versuchsdesigns mit sportwissenschaftlicher Expertise gewährleistet dabei die physiologische Validität der erfassten Belastungs- und Ermüdungsdaten. Die geplante öffentliche Bereitstellung dieses Datensatzes wird die Reproduzierbarkeit der Ergebnisse gewährleisten und eine valide Grundlage für zukünftige Forschungen in der sportwissenschaftlichen Sensorik darstellen.

Die vergleichende Analyse der beiden entwickelten Modellarchitekturen, dem Feature-basierten XGBoost-Modell und dem Rohdaten-basierten Attention-Modell, hat die signifikante Überlegenheit beider Ansätze gegenüber einfachen Baseline-Modellen klar belegt. Beide Architekturen bewiesen ihre Fähigkeit, komplexe, nicht-lineare Muster in den zugrundeliegenden Bewegungsdaten zu erkennen, was zu einer hohen Genauigkeit bei der Vorhersage des Ermüdungsgrades führte.

Insbesondere die Ergebnisse des XGBoost-Modells lieferten eine wichtige biomechanische Erkenntnis: Die Frequenzmerkmale der Beinbewegungen wurden als die wichtigsten Merkmale für die Ermüdung erkannt. Dies stützt die Annahme, dass der Leistungsverlust beim Klettern sich nicht nur in nachlassender Griffkraft, sondern auch in Veränderungen der Beinarbeit zeigt. Im Gegensatz dazu lieferte das Attention-Modell die besten Vorhersageergebnisse und zeigte eine robuste Generalisierungsfähigkeit, was das Potenzial sequenzieller Modellierung zur automatischen Extraktion relevanter Muster aus den Rohdaten unterstreicht.

Die Arbeit bestätigt somit das Potenzial fortgeschrittener Machine-Learning-Verfahren, um objektive und nicht-invasive Monitoring-Tools für den Klettersport zu entwickeln. Trotz der Limitationen durch die Stichprobengröße und das Studiendesign stellen die entwickelten Modelle einen validen Ausgangspunkt für die präzisere Trainingssteuerung und Verletzungsprävention dar. Die Erkenntnisse legen nahe, dass zukünftige Anstrengungen auf die Vereinfachung des Sensor-Setups und die Verfeinerung der zeitlichen Musterer-

kennung gerichtet sein sollten, um die Praxistauglichkeit der Methode zu erhöhen.

8.2 AUSBLICK

Um die Generalisierbarkeit der Modelle zu erhöhen und die Limitation der kleinen Stichprobengröße zu überwinden, ist eine Erweiterung des Datensatzes erforderlich. Zukünftige Studien sollten eine größere und heterogenere Gruppe von Kletterern (unterschiedliche Leistungsniveaus und Kletterstile) einbeziehen. Darüber hinaus sollte das Versuchsdesign um eine echte Kontrollgruppe erweitert werden, um die Robustheit der Modelle gegenüber nicht ermüdungsbedingten Bewegungsvariationen zu testen. Die Veröffentlichung des Datensatzes bietet hier eine Grundlage für weitere Forschung.

Die Ergebnisse zeigten die hohe Relevanz von Frequenzmerkmalen der Beinbewegungen. Zukünftige Arbeiten sollten untersuchen, ob eine gezieltere Feature-Entwicklung unter Einbeziehung biomechanischer Modelle die Vorhersagekraft weiter steigern kann. Bei den Attention-Modellen ist eine weitere Hyperparameter-Optimierung der Windowing-Parameter sowie die Untersuchung anderer Sequenz-Modelle vielversprechend.

Ein wichtiger Schritt für die Anwendung in der Praxis ist die Reduktion der benötigten Sensoren. Es sollte untersucht werden, ob eine minimierte Sensorkonfiguration, die eine praktikablere Anwendung im Alltag ermöglicht, ähnliche Vorhersagegenauigkeiten erreicht. Es ist sinnvoll, verschiedene Kombinationen von Sensoren zu testen, z.B. ausschließlich Sensoren an einem Armgelenk und der Hüfte. Dies würde die Übertragbarkeit der Modelle auf gängige tragbare Geräte wie Smartwatches und Smartphones (die oft nur an diesen Positionen getragen werden) ermöglichen. Ziel ist die Entwicklung eines robusten und alltagstauglichen Echtzeit-Ermüdungsmonitors, der Kletterern und Trainern eine objektive Grundlage für Trainingssteuerung und Verletzungsprävention liefert.

Teil II

APPENDIX

A. APPENDIX

A.1 PYTHON VERSIONEN UND ABHÄNGIGKEITEN

A.1.1 *Multi-Sensor-Aufzeichnungssystem*

Python: 3.13

Abhängigkeiten:

```
"bleak">=0.22.3",
"loguru">=0.7.3",
"pandas">=2.2.3",
"pyarrow">=20.0.0",
"pydantic">=2.11.3",
```

A.1.2 *Datenvorverarbeitung und Modellierung*

Python: 3.11

Abhängigkeiten:

```
"ipykernel">=6.29.5",
"keras">=3.11.1",
"matplotlib">=3.10.3",
"openpyxl">=3.1.5",
"pandas">=2.2.3",
"pyarrow">=20.0.0",
"scikit-learn">=1.7.0",
"scipy">=1.15.3",
"seaborn">=0.13.2",
"tensorflow[and-cuda]>=2.19.0",
"xgboost">=3.0.2",
"sktime">=0.38.4",
"numba">=0.61.2",
"xgboost">=3.0.4",
"mlflow">=3.3.1",
```

A.2 HYPERPARAMETER

A.2.1 *Feature-basiertes XGBoost-Modell*

```
"n_estimators": 10,
"learning_rate": 0.01,
"max_depth": 3,
"subsample": 0.8,
"colsample_bytree": 0.5,
```

```
"colsample_bylevel": 0.3,
"reg_alpha": 1.0,
"reg_lambda": 1.0,
```

Listing A.1: Verwendete Hyperparameter beim Modelltraining

```
{
  "learner": {
    "generic_param": {
      "device": "cuda:0",
      "fail_on_invalid_gpu_id": "0",
      "n_jobs": "0",
      "nthread": "0",
      "random_state": "0",
      "seed": "0",
      "seed_per_iteration": "0",
      "validate_parameters": "1"
    },
    "gradient_booster": {
      "gbtree_model_param": {
        "num_parallel_tree": "1",
        "num_trees": "10"
      },
      "gbtree_train_param": {
        "process_type": "default",
        "tree_method": "auto",
        "updater": "grow_gpu_hist",
        "updater_seq": "grow_gpu_hist"
      },
      "name": "gbtree",
      "specified_updater": false,
      "tree_train_param": {
        "alpha": "1",
        "cache_opt": "1",
        "colsample_bylevel": "0.3000000012",
        "colsample_bynode": "1",
        "colsample_bytree": "0.5",
        "eta": "0.00999999978",
        "gamma": "0",
        "grow_policy": "depthwise",
        "interaction_constraints": "",
        "lambda": "1",
        "learning_rate": "0.00999999978",
        "max_bin": "256",
        "max_cat_threshold": "64",
        "max_cat_to_onehot": "4",
        "max_delta_step": "0",
        "max_depth": "3",
        "max_leaves": "0",
        "min_child_weight": "1",
        "min_split_loss": "0",
        "monotone_constraints": "()",
        "refresh_leaf": "1",
```

```

        "reg_alpha": "1",
        "reg_lambda": "1",
        "sampling_method": "uniform",
        "sketch_ratio": "2",
        "sparse_threshold": "0.20000000000000001",
        "subsample": "0.800000012"
    },
    "updater": [
        {
            "hist_train_param": {
                "debug_synchronize": "0",
                "extmem_single_page": "0",
                "max_cached_hist_node": "18446744073709551615"
            },
            "name": "grow_gpu_hist"
        }
    ],
    "learner_model_param": {
        "base_score": "2.6706758E-1",
        "boost_from_average": "1",
        "num_class": "0",
        "num_feature": "46620",
        "num_target": "1"
    },
    "learner_train_param": {
        "booster": "gbtree",
        "disable_default_eval_metric": "0",
        "multi_strategy": "one_output_per_tree",
        "objective": "reg:squarederror"
    },
    "metrics": [
        {
            "name": "rmse"
        }
    ],
    "objective": {
        "name": "reg:squarederror",
        "reg_loss_param": {
            "scale_pos_weight": "1"
        }
    },
    "version": [
        3,
        0,
        4
    ]
}

```

Listing A.2: Vollständige Parameter

A.2.2 Rohdaten-basiertes Attention-Modell

```

inputs = Input(shape=(SEGMENT_LENGTH, 12))
x = Conv1D(64, kernel_size=5, activation='relu', padding='causal')(
    inputs)
x = LayerNormalization(epsilon=1e-6)(x)
x = MultiHeadAttention(num_heads=4, key_dim=32, dropout=0.2)(x, x, use_
    causal_mask=True)
x = GlobalAveragePooling1D()(x)
x = Dropout(0.3)(x)
outputs = Dense(1, activation="linear")(x)

model = Model(inputs, outputs)
optimizer = Adam(learning_rate=3e-4)
model.compile(optimizer=optimizer, loss="mse", metrics=["mae"])

callbacks = [
    EarlyStopping(patience=10, monitor='val_mae', mode='min'),
    ReduceLROnPlateau(factor=0.5, patience=3, verbose=1),
    ModelCheckpoint('best_model.h5', save_best_only=True)
]

history = model.fit(
    X_train_scaled, y_train,
    batch_size=32,
    epochs=30,
    validation_data=(X_val_scaled, y_val),
    callbacks=callbacks,
    verbose=0
)

```

A.3 ERGEBNISSE DER LEAVE-ONE-SUBJECT-OUT CROSS-VALIDATION

A.3.1 *Feature-basiertes XGBoost-Modell*

Proband als Test	MAE Test	MAE Train	Spearman Korrelation
1	0,1935	0,1843	0,6
2	0,2250	0,1811	0,4
3	0,1857	0,1858	-0,4
4	0,0978	0,1951	-0,8
5	0,1986	0,1838	0,4
6	0,1969	0,1842	-0,2
7	0,1804	0,1858	-0,2
8	0,1778	0,1855	-0,4
9	0,2696	0,1774	0,2
10	0,2098	0,1831	-0,8

Tabelle A.1: Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit MinimalFCParameters

Proband als Test	MAE Test	MAE Train	Spearman Korrelation
1	0,1984	0,1824	0,8
2	0,2268	0,1798	0,2
3	0,1827	0,1841	0,4
4	0,0972	0,1933	-0,6
5	0,1990	0,1823	-0,2
6	0,1977	0,1827	0
7	0,1792	0,1842	0,4
8	0,1788	0,1839	-0,8
9	0,2694	0,1758	1
10	0,2075	0,1819	0,8

Tabelle A.2: Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit EfficientFCParameters

Proband als Test	MAE Test	MAE Train	Spearman Korrelation
1	0,1947	0,1824	-0,4
2	0,2266	0,1796	-0,4
3	0,1813	0,1836	0,2
4	0,0951	0,1927	-0,4
5	0,1981	0,1821	0,6
6	0,1975	0,1832	-0,4
7	0,1816	0,1838	0,4
8	0,1775	0,1839	0,4
9	0,2705	0,1756	0,8
10	0,2084	0,1822	1,0

Tabelle A.3: Ergebnis der Leave-One-Subject-Out Cross-Validation für das XGBoost-Modell mit EfficientFCParameters + Körperrelation

A.3.2 Rohdaten-basiertes Attention-Modell

Proband als Test	MAE Test	MAE Train	Spearman Korrelation
1	0,1373	0,1459	0,2689
2	0,1337	0,1633	0,4900
3	0,1456	0,1571	-0,1719
4	0,0640	0,1574	0,6355
5	0,1069	0,1416	0,4197
6	0,1062	0,1564	0,6226
7	0,1112	0,1563	0,4793
8	0,0991	0,1562	0,5634
9	0,1484	0,1561	0,6265
10	0,1794	0,1400	-0,1064

Tabelle A.4: Ergebnis der Leave-One-Subject-Out Cross-Validation für das beste Attention-Modell (Segmentlänge = 1000, Fensterschritt = 100)

A. LITERATUR

-
- [1] Per Aagaard, Erik B. Simonsen, Jesper L. Andersen, Peter Magnusson und Poul Dyhre-Poulsen. "Increased Rate of Force Development and Neural Drive of Human Skeletal Muscle Following Resistance Training". In: *Journal of Applied Physiology* 93.4 (Okt. 2002), S. 1318–1326. ISSN: 8750-7587. DOI: [10.1152/japplphysiol.00283.2002](https://doi.org/10.1152/japplphysiol.00283.2002).
 - [2] Markus Amann und Jerome A. Dempsey. "Locomotor Muscle Fatigue Modifies Central Motor Drive in Healthy Humans and Imposes a Limitation to Exercise Performance". In: *The Journal of Physiology* 586.1 (2008), S. 161–173. ISSN: 1469-7793. DOI: [10.1113/jphysiol.2007.141838](https://doi.org/10.1113/jphysiol.2007.141838).
 - [3] Arif Amca, Laurent Vigouroux, Serdar Arıtan und Eric Berton. "Effect of Hold Depth and Grip Technique on Maximal Finger Forces in Rock Climbing". In: *Journal of sports sciences* 30 (Feb. 2012), S. 669–77. DOI: [10.1080/02640414.2012.658845](https://doi.org/10.1080/02640414.2012.658845).
 - [4] Attila Biró, Antonio Ignacio Cuesta-Vargas und László Szilágyi. "AI-assisted Fatigue and Stamina Control for Performance Sports on IMU-generated Multivariate Times Series Datasets". In: *Sensors* 24.1 (2024), S. 132.
 - [5] Jérémie Boulanger, Ludovic Seifert, Romain Hérault und Jean-Francois Coeurjolly. "Automatic Sensor-Based Detection and Classification of Climbing Activities". In: *IEEE Sensors Journal* 16.3 (2015), S. 742–749.
 - [6] Cillian Buckley, Martin A. O'Reilly, Darragh Whelan, A. Valley Farrell, L. Clark, V. Longo, M. D. Gilchrist und Brian Caulfield. "Binary Classification of Running Fatigue Using a Single Inertial Measurement Unit". In: *2017 IEEE 14th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*. IEEE, 2017, S. 197–201.
 - [7] Dirk Büsch, Till Utesch und Franz Marschall. "Entwicklung und Evaluation der Anstrengungsskala Sport". In: *German Journal of Exercise and Sport Research* 52.1 (März 2022), S. 173–178. ISSN: 2509-3150. DOI: [10.1007/s12662-021-00757-z](https://doi.org/10.1007/s12662-021-00757-z).
 - [8] Pengfei Chang, Cenyi Wang, Yiyan Chen, Guodong Wang und Aming Lu. "Identification of Runner Fatigue Stages Based on Inertial Sensors and Deep Learning". In: *Frontiers in Bioengineering and Biotechnology* 11 (2023), S. 1302911.
 - [9] Tianqi Chen und Carlos Guestrin. "XGBoost: A Scalable Tree Boosting System". In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Aug. 2016, S. 785–794. DOI: [10.1145/2939672.2939785](https://doi.org/10.1145/2939672.2939785). arXiv: [1603.02754 \[cs\]](https://arxiv.org/abs/1603.02754).

- [10] Maximilian Christ, Nils Braun, Julius Neuffer und Andreas W. Kempa-Liehr. "Time Series Feature Extraction on Basis of Scalable Hypothesis Tests (Tsfresh – A Python Package)". In: *Neurocomputing* 307 (Sep. 2018), S. 72–77. ISSN: 0925-2312. DOI: [10.1016/j.neucom.2018.03.067](https://doi.org/10.1016/j.neucom.2018.03.067).
- [11] Samuel D'Emanuele, Nicola A. Maffiuletti, Cantor Tarperi, Alberto Rainoldi, Federico Schena und Gennaro Boccia. "Rate of Force Development as an Indicator of Neuromuscular Fatigue: A Scoping Review". In: *Frontiers in Human Neuroscience* 15 (Juli 2021). ISSN: 1662-5161. DOI: [10.3389/fnhum.2021.701916](https://doi.org/10.3389/fnhum.2021.701916).
- [12] Deutscher Alpenverein. *Was ist Bouldern?* https://www.alpenverein.de/artikel/was-ist-bouldern_133a0047-bb6c-498b-9004-742a32c2d065. Sep. 2025.
- [13] J. Diebel. "Representing Attitude : Euler Angles , Unit Quaternions , and Rotation Vectors". In: 2006.
- [14] Wilfried Elmenreich. "An Introduction to Sensor Fusion". Diss. Austria: Vienna University of Technology, 2022.
- [15] Maurizio Fanchini, Frédéric Violette, Franco M. Impellizzeri und Nicola A. Maffiuletti. "Differences in Climbing-Specific Strength Between Boulder and Lead Rock Climbers". In: *The Journal of Strength & Conditioning Research* 27.2 (Feb. 2013), S. 310. ISSN: 1064-8011. DOI: [10.1519/JSC.0b013e3182577026](https://doi.org/10.1519/JSC.0b013e3182577026).
- [16] Jerome H. Friedman. "Greedy Function Approximation: A Gradient Boosting Machine". In: *The Annals of Statistics* 29.5 (2001), S. 1189–1232. ISSN: 0090-5364. JSTOR: [2699986](https://www.jstor.org/stable/2699986).
- [17] Davoud Gholamiangonabadi, Nikita Kiselov und Katarina Grolinger. "Deep Neural Networks for Human Activity Recognition With Wearable Sensors: Leave-One-Subject-Out Cross-Validation for Model Selection". In: *IEEE Access* 8 (2020), S. 133982–133994. ISSN: 2169-3536. DOI: [10.1109/ACCESS.2020.3010715](https://doi.org/10.1109/ACCESS.2020.3010715).
- [18] Juan José González-Badillo, Juan Manuel Yáñez-García, Ricardo Mora-Custodio und David Rodríguez-Rosell. "Velocity Loss as a Variable for Monitoring Resistance Exercise". In: *International Journal of Sports Medicine* 38.3 (März 2017), S. 217–225. ISSN: 0172-4622, 1439-3964. DOI: [10.1055/s-0042-120324](https://doi.org/10.1055/s-0042-120324).
- [19] Soree Hwang, Nayeon Kwon, Dongwon Lee, Jongman Kim, Sumin Yang, Inchan Youn, Hyuk-June Moon, Joon-Kyung Sung und Sungmin Han. "A Multimodal Fatigue Detection System Using sEMG and IMU Signals with a Hybrid CNN-LSTM-Attention Model". In: *Sensors* 25.11 (Jan. 2025), S. 3309. ISSN: 1424-8220. DOI: [10.3390/s25113309](https://doi.org/10.3390/s25113309).
- [20] Yanran Jiang, Peter Malliaras, Bernard Chen und Dana Kulić. "Real-Time Forecasting of Exercise-Induced Fatigue from Wearable Sensors". In: *Computers in Biology and Medicine* 148 (Sep. 2022), S. 105905. ISSN: 0010-4825. DOI: [10.1016/j.compbiomed.2022.105905](https://doi.org/10.1016/j.compbiomed.2022.105905).

- [21] Swapnali Karvekar, Masoud Abdollahi und Ehsan Rashedi. "A Data-Driven Model to Identify Fatigue Level Based on the Motion Data from a Smartphone". In: *BioRxiv* (2019), S. 796854.
- [22] Howard Knuttgen und William Kraemer. "Terminology and Measurement in Exercise Performance". In: *The Journal of Strength & Conditioning Research* 1 (Feb. 1987), S. 1–10. DOI: [10.1519/00124278-198702000-00001](https://doi.org/10.1519/00124278-198702000-00001).
- [23] Tom L. Koller, Tim Laue und Udo Frese. "Event-Domain Knowledge in Inertial Sensor Based State Estimation of Human Motion". In: *2022 25th International Conference on Information Fusion (FUSION)*. Juli 2022, S. 01–08. DOI: [10.23919/FUSION49751.2022.9841378](https://doi.org/10.23919/FUSION49751.2022.9841378).
- [24] Felix Kosmalla, Florian Daiber und Antonio Krüger. "ClimbSense: Automatic Climbing Route Recognition Using Wrist-worn Inertia Measurement Units". In: *Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*. Seoul Republic of Korea: ACM, Apr. 2015, S. 2033–2042. ISBN: 978-1-4503-3145-6. DOI: [10.1145/2702123.2702311](https://doi.org/10.1145/2702123.2702311).
- [25] Dominik Krumm, Stefan Schwanitz und Stephan Odenwald. *Spinfortec2022 : Tagungsband Zum 14. Symposium Der Sektion Sportinformatik Und Sporttechnologie Der Deutschen Vereinigung Für Sportwissenschaft (Dvs) Chemnitz 29. - 30. September 2022*. Sep. 2022. ISBN: 978-3-96100-176-7.
- [26] Pranav Madhav Kuber, Abhineet Rajendra Kulkarni und Ehsan Rasheidi. "Machine Learning-Based Fatigue Level Prediction for Exoskeleton-Assisted Trunk Flexion Tasks Using Wearable Sensors". In: *Applied Sciences* 14.11 (2024), S. 4563.
- [27] Jan Kuschan und Jörg Krüger. "Fatigue Recognition in Overhead Assembly Based on a Soft Robotic Exosuit for Worker Assistance". In: *CIRP Annals* 70.1 (Jan. 2021), S. 9–12. ISSN: 0007-8506. DOI: [10.1016/j.cirp.2021.04.034](https://doi.org/10.1016/j.cirp.2021.04.034).
- [28] Cassim Ladha, Nils Hammerla, Patrick Olivier und Thomas Ploetz. "ClimbAX: Skill Assessment for Climbing Enthusiasts". In: *UbiComp 2013 - Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. Sep. 2013. DOI: [10.1145/2493432.2493492](https://doi.org/10.1145/2493432.2493492).
- [29] Arsalan Lambay, Ying Liu, Phillip Morgan und Ze Ji. "A Data-Driven Fatigue Prediction Using Recurrent Neural Networks". In: *2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*. IEEE, 2021, S. 1–6.
- [30] Guillaume Levernier und Guillaume Laffaye. "Rate of Force Development and Maximal Force: Reliability and Difference between Non-Climbers, Skilled and International Climbers". In: *Sports Biomechanics* 20.4 (Mai 2021), S. 495–506. ISSN: 1476-3141. DOI: [10.1080/14763141.2019.1584236](https://doi.org/10.1080/14763141.2019.1584236).

- [31] G. Mandelli und A. Angriman. "Scales of Difficulty in Climbing". In: 2016.
- [32] Luca Marotta, Jaap H. Buurke, Bert-Jan F. van Beijnum und Jasper Reenalda. "Towards Machine Learning-Based Detection of Running-Induced Fatigue in Real-World Scenarios: Evaluation of IMU Sensor Configurations to Reduce Intrusiveness". In: *Sensors* 21.10 (Jan. 2021), S. 3451. ISSN: 1424-8220. DOI: [10.3390/s21103451](https://doi.org/10.3390/s21103451).
- [33] Michail Lubomirov Michailov, Baláš Jiří, Tanev Stoyan Kolev, Andonov Hristo Stoyanov, Kodejška Jan und Lee and Brown. "Reliability and Validity of Finger Strength and Endurance Measurements in Rock Climbing". In: *Research Quarterly for Exercise and Sport* 89.2 (Apr. 2018), S. 246–254. ISSN: 0270-1367. DOI: [10.1080/02701367.2018.1441484](https://doi.org/10.1080/02701367.2018.1441484).
- [34] D. Micklewright, A. St Clair Gibson, V. Gladwell und A. Al Salman. "Development and Validity of the Rating-of-Fatigue Scale". In: *Sports Medicine* 47.11 (Nov. 2017), S. 2375–2393. ISSN: 1179-2035. DOI: [10.1007/s40279-017-0711-5](https://doi.org/10.1007/s40279-017-0711-5).
- [35] Philipp Niklas Müller, Alexander Josef Müller, Philipp Achenbach und Stefan Göbel. "IMU-Based Fitness Activity Recognition Using CNNs for Time Series Classification". In: *Sensors* 24.3 (Jan. 2024), S. 742. ISSN: 1424-8220. DOI: [10.3390/s24030742](https://doi.org/10.3390/s24030742).
- [36] Tim Op De Beéck, Wannes Meert, Kurt Schütte, Benedicte Vanwanseele und Jesse Davis. "Fatigue Prediction in Outdoor Runners Via Machine Learning and Sensor Fusion". In: *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London United Kingdom: ACM, Juli 2018, S. 606–615. ISBN: 978-1-4503-5552-0. DOI: [10.1145/3219819.3219864](https://doi.org/10.1145/3219819.3219864).
- [37] Julien Pansiot, Rachel C. King, Douglas G. McIlwraith, Benny PL Lo und Guang-Zhong Yang. "ClimBSN: Climber Performance Monitoring with BSN". In: *2008 5th International Summer School and Symposium on Medical Devices and Biosensors*. IEEE, 2008, S. 33–36.
- [38] Marcus Schmidt, Carl Christian Rheinländer, Sebastian Wille, Norbert Wehn und Thomas Jaitner. "IMU-based Determination of Fatigue during Long Sprint". In: *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct*. UbiComp '16. New York, NY, USA: Association for Computing Machinery, Sep. 2016, S. 899–903. ISBN: 978-1-4503-4462-3. DOI: [10.1145/2968219.2968575](https://doi.org/10.1145/2968219.2968575).
- [39] Karl Söderqvist, Fredrik Identeg, Jonas Zimmerman, Eric Hamrin Senorski, Mikael Sansone und Henrik Hedelin. "Validity and Reliability of Finger-Strength Testing in 6 Common Grip Techniques for the Assessment of Bouldering Ability in Men". In: *International Journal of Sports Physiology and Performance* 19.3 (Feb. 2024), S. 290–298. ISSN: 1555-0273, 1555-0265. DOI: [10.1123/ij spp.2023-0129](https://doi.org/10.1123/ij spp.2023-0129).

- [40] Cesar Sordo-Vacas, Amador Garcia-Ramos und David Colomer-Poveda. "Intra and Inter-Session Reliability of Movement Velocity During Pull-Ups Performed at Small Climbing Holds". In: *Journal of Musculoskeletal & Neuronal Interactions* 24.4 (2024), S. 370–376. ISSN: 1108-7161.
- [41] Nicolay Stien, Vegard Albert Vereide, Atle Hole Saeterbakken, Espen Hermans, Matthew Peter Shaw und Vidar Andersen. "Upper Body Rate of Force Development and Maximal Strength Discriminates Performance Levels in Sport Climbing". In: *PLOS ONE* 16.3 (März 2021), e0249353. ISSN: 1932-6203. DOI: [10.1371/journal.pone.0249353](https://doi.org/10.1371/journal.pone.0249353).
- [42] María Fernanda Trujillo-Guerrero, Stadyñ Román-Niemes, Milagros Jaén-Vargas, Alfonso Cadiz, Ricardo Fonseca und José Javier Serrano-Olmedo. "Accuracy Comparison of CNN, LSTM, and Transformer for Activity Recognition Using IMU and Visual Markers". In: *IEEE Access* 11 (2023), S. 106650–106669. ISSN: 2169-3536. DOI: [10.1109/ACCESS.2023.3318563](https://doi.org/10.1109/ACCESS.2023.3318563).
- [43] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser und Illia Polosukhin. "Attention Is All You Need". In: *Advances in Neural Information Processing Systems*. Bd. 30. Curran Associates, Inc., 2017.
- [44] Vegard Vereide, Vidar Andersen, Espen Hermans, Jarle Kalland, Atle Hole Saeterbakken und Nicolay Stien. "Differences in Upper-Body Peak Force and Rate of Force Development in Male Intermediate, Advanced, and Elite Sport Climbers". In: *Frontiers in Sports and Active Living* 4 (Juni 2022). ISSN: 2624-9367. DOI: [10.3389/fspor.2022.888061](https://doi.org/10.3389/fspor.2022.888061).
- [45] WITMOTION. *WITMOTION/WitBluetooth_BWT901BLE5_o*. https://github.com/WITMOTION/WitBluetooth_BWT901BLE5_o. Sep. 2025.
- [46] WMA Declaration of Helsinki – Ethical Principles for Medical Research Involving Human Participants. <https://www.wma.net/policies-post/wma-declaration-of-helsinki/>.
- [47] Guodong Wang, Xiaokun Mao, Qiuxia Zhang und Aming Lu. "Fatigue Detection in Running with Inertial Measurement Unit and Machine Learning". In: *2022 10th International Conference on Bioinformatics and Computational Biology (ICBCB)*. IEEE, 2022, S. 85–90.
- [48] Phillip B. Watts. "Physiology of Difficult Rock Climbing". In: *European Journal of Applied Physiology* 91.4 (Apr. 2004), S. 361–372. ISSN: 1439-6327. DOI: [10.1007/s00421-003-1036-7](https://doi.org/10.1007/s00421-003-1036-7).
- [49] Lichen Zhang, Mohsen Mutasem Diraneyya, JuHyeong Ryu, Carl T. Haas und Eihab Abdel-Rahman. "Assessment of Jerk as a Method of Physical Fatigue Detection". In: *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*. Bd. 51739. American Society of Mechanical Engineers, 2018, V01BT02A010.

- [50] Lichen Zhang, Mohsen Mutasem Diraneyya, Juhyeong Ryu, C. T. Haas und Eihab Abdel-Rahman. "Automated Monitoring of Physical Fatigue Using Jerk". In: *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction*. Bd. 36. IAARC Publications, 2019, S. 989–997.