

Erkennung von Leistungsverlust beim Klettern durch IMU-Sensordaten:

Studienbasierte Datenerhebung mit einem Multi-Sensor-Aufzeichnungssystem und Modellentwicklung

Danilo Zähle

Referent: Prof. Dr. Timo Schürg, Korreferent: Prof. Dr. Kawa Nazemi



Motivation

Die objektive Ermüdungsbeurteilung im Klettersport stellt eine methodische Herausforderung dar. Bisherige Verfahren basieren überwiegend auf subjektiven Skalen oder invasiven Labormessungen, was eine kontinuierliche objektive Überwachung erschwert. IMU-Sensoren können diese Lücke schließen, indem sie Bewegungsdaten erfassen, die Ermüdungssignaturen wie nachlassende Stabilität abbilden. Die wissenschaftliche Herausforderung liegt in der Anwendung maschineller Lernverfahren, um relevante Muster für die Ermüdungsvorhersage zu extrahieren.

Diese Masterarbeit verfolgt zwei Ziele: Erstens die Generierung eines studienbasierten Datensatzes mit IMU-Daten von zehn Probanden während wiederholter Bouldersequenzen, wobei Ermüdung durch Kraftmessungen und Befragungen quantifiziert wurde. Zweitens die Entwicklung und Evaluation zweier datenbasierter Vorhersagemodelle: ein feature-basiertes XGBoost-Modell und ein rohdatenbasiertes Deep-Learning-Modell mit Attention-Mechanismus. Die Arbeit bewertet beide Ansätze und stellt den Datensatz zur Sicherung der Reproduzierbarkeit öffentlich bereit.

Studie zur Sensordatenaufzeichnung mit Probanden

Um einen Datensatz für die Ermüdungsvorhersage beim Bouldern zu generieren, wurde eine Studie mit zehn erfahrenen Kletterern durchgeführt. Jeder Proband absolvierte ein individuell abgestimmtes, wiederholtes Boulderproblem an einem Kilterboard (40° Neigung), während Bewegungsdaten mit fünf IMU-Sensoren (200 Hz) an Handgelenken, Knöcheln und Hüfte erfasst wurden.



Die Ermüdung wurde vor jedem Kletterdurchgang objektiv mittels Kraftmessungen (Rate of Force Development, Maximalkraft der Finger) und subjektiv über standardisierte Skalen (Rating-of-Fatigue, Anstrengungsskala Sport) quantifiziert. Der Versuchsablauf umfasste ein Aufwärmen, gefolgt von vier identischen Messblöcken, die durch 18-minütige Trainingsintervalle zur Steigerung der Ermüdung getrennt waren.


Ein eigens entwickeltes Multi-Sensor-Aufzeichnungssystem gewährleistete die synchrone Datenerfassung. Für die Studie wurde dieses System in Python programmiert, da bestehende Lösungen die spezifischen Anforderungen nicht erfüllten. Das Kernstück der Software ist ihre asynchrone Architektur. Diese

ermöglicht es, alle fünf Sensoren gleichzeitig zu verwalten und deren Daten parallel zu erfassen, ohne dass es zu Verzögerungen kommt. Besonderer Wert wurde auf die Robustheit des Systems gelegt. Bei einem Verbindungsabbruch versucht es automatisch, die Verbindung zum Sensor wiederherzustellen. Ein umfangreiches Logging protokolliert alle wichtigen Ereignisse. Der so generierte Datensatz wird öffentlich zugänglich gemacht, um die Reproduzierbarkeit zu sichern.

Methodik

Um die Ermüdung vorherzusagen, wurde ein Ermüdungsindex aus objektiven Kraftmessungen (Maximalkraft, RFD_{200ms}) und subjektiven Skalen (ROF, ASS) gebildet, standardisiert und auf [0,1] normalisiert.

$$y = 0.4 \cdot \text{ROF} + 0.1 \cdot \text{ASS} + 0.25 \cdot F_{\text{max}} + 0.25 \cdot \text{RFD}_{200\text{ms}}$$



Die Auswertung des erstellten Datensatzes zeigt einen klaren Anstieg des berechneten Ermüdungsindex über die Versuche hinweg, was die intendierte Ermüdungsprogression validiert.

Die IMU-Rohdaten der Kletterversuche wurden bereinigt (Duplikate und Ausreißer), in ein globales Koordinatensystem transformiert und für zwei Modellansätze aufbereitet:

1. **Feature-basiert:** Automatische Merkmalsextraktion mit tsfresh und ergänzenden Sensor-Kombinationsfeatures.
2. **Rohdaten-basiert:** Zeitreihen wurden segmentiert (Windowing) und die Zielvariable interpoliert.


Es wurden drei Modelle evaluiert:

- **Baseline-Modelle:** Ein Zufallsmodell generiert gleichmäßig verteilte Werte zwischen 0 und 1, während ein lineares Modell einen kontinuierlichen Anstieg der Ermüdung über die Versuchsdurchgänge hinweg abbildet.
- **XGBoost-Modell:** Trainiert auf den extrahierten Features mit Regularisierung und Sampling zur Vermeidung von Overfitting.

- **Attention-Modell:** Ein hybrides CNN mit Masked-Multi-Head-Attention, das direkt auf den segmentierten Zeitreihen trainiert.

Die Bewertung erfolgte mittels Leave-One-Subject-Out Cross-Validation anhand des Mean Absolute Error (MAE) und der Spearman-Korrelation.

Ergebnisse



Die Modellvergleiche demonstrieren die Überlegenheit der datengetriebenen Ansätze: Das XGBoost-Modell (MAE: 0,1931) identifizierte Frequenzmerkmale der Beinbewegungen als entscheidend für die Vorhersage, wobei insbesondere rhythmische Muster der Beine die höchste Vorhersagerelevanz zeigten. Das Attention-Modell erzielte mit einem MAE von 0,1232 die genauesten Vorhersagen und erreichte mit einer Spearman-Korrelation von 0,3828 die beste Erfassung des Ermüdungstrends aller trainierten Modelle. Es profitiert dabei von längeren Segmentlängen mit hoher Überlappung.

Die Ergebnisse verdeutlichen einen wichtigen Trade-off: Während das einfache Baseline-Increase-Modell zwar eine perfekte Spearman-Korrelation von 1 erzielt, aber in der absoluten Vorhersagegenauigkeit (MAE) versagt, erreichen die komplexeren Modelle eine robuste und ausgewogene Leistung über beide entscheidenden Bewertungsdimensionen hinweg.

Fazit

Diese Arbeit demonstriert die erfolgreiche Vorhersage von Kletterermüdung mittels IMU-Sensordaten und maschinellen Lernen. Der Kernbeitrag ist ein neu generierter, öffentlich zugänglicher Datensatz, der die Ermüdungsentwicklung von zehn Probanden über standardisierte Kletterversuche erfasst.

Die vergleichende Analyse zweier Modellansätze belegt die Überlegenheit datengetriebener Verfahren: Während das XGBoost-Modell die Relevanz von Beinbewegungsfrequenzen für die Ermüdung aufzeigt, erzielt das Attention-Modell die robusteste Vorhersagegenauigkeit durch automatische Mustererkennung in den Rohdaten. Die Arbeit bestätigt das Potenzial für objektive Ermüdungsmonitorings.

Zukünftige Arbeiten sollten die Generalisierbarkeit durch erweiterte Datensätze verbessern und die Praxistauglichkeit durch minimierte Sensor-Setups für alltagstaugliche Anwendungen wie Smartwatches vorantreiben.