

Aktivitätsklassifikation in IMU-basierten Mobilitätsdaten




Abb. 1: Visualisierung PCA-Analyse sub-k10




Abb. 3: Cumulative Variance




Abb. 2: Confusion Matrix Fein




Abb. 4: Confusion Matrix Grob

Problemstellung

In der stationären Neurorehabilitation verbringen Patienten den Grossteil ihres Tages ausserhalb der formalen Therapiesitzungen. Bisher wird dieses spontane Aktivitätsniveau meist nur grob geschätzt, da standardisierte Assessments primär die Leistungsfähigkeit unter künstlichen Testbedingungen prüfen, statt den tatsächlichen Bewegungsalltag abzubilden.

Klinische Entscheidungen basieren daher oft auf subjektiven, momentänen Einschätzungen, statt auf präzisen Aktivitätsprofilen. Die tatsächliche Therapieintensität und das Ausmass des sogenannten Sedentary Behaviour bleiben quantitativ unklar.

Der Einsatz von tragbaren Sensoren (IMUs, Inertial Measurement Units) bietet die Chance, durch automatisierte Aktivitätsklassifikation kontinuierliche und objektive Daten zu generieren. Dies ermöglicht eine gezieltere Interventionsplanung und eine differenzierte Überprüfung des Rehabilitationserfolgs im klinischen Alltags.

Lösungskonzept

In einer ersten Phase wurde die optimale Position für die Sensoren, in Bezug auf Anwenderfreundlichkeit und Aktivitätserkennung, ermittelt. In einem weiteren Schritt wurden relevante, gelabelte Daten erhoben, mit denen man geeignetes Feature-engineering betreiben kann, mit welchen anschliessend ein geeignetes ML-Modell trainiert werden kann.

Ergebnisse

Die Feinklassifikation erreicht ein makro-gemittelt F1-Mass von rund 0,71 bei erheblicher personenweiser Streuung; entlang der Hierarchie gelingt die binäre Trennung nahezu fehlerfrei ($\approx 0,97$), während die feine Differenzierung ähnlicher Aktivitäten abfällt. Zwischen den fünf Modellvarianten bestehen nur marginale Unterschiede, und der erwartete Vorteil des zweistufigen Ansatzes zeigt sich nicht. Eine einseitige Zwei-Sensor-Konfiguration ist mit der beidseitigen Vier-Sensor-Variante vergleichbar (je $\approx 0,72$, stützt H_2) und 20 Hz genügt gegenüber 50 Hz (stützt H_3), sofern obere und untere Extremität abgedeckt sind. Offen

bleiben die Hypothesen zu Deep-Learning (H_1) und Befestigungsgenauigkeit (H_4), die mangels Daten nicht abschliessend evaluiert werden konnten.

Marcel Bossard

Hauptbetreuer
Prof. Dr. Patric Eberle

Experte/Expertin
Reto Jäggi, MSc Elektrotechnik ETH

Kooperationspartner
Universität Luzern, Prof. Dr. Matthias Ertl

**UNIVERSITÄT
LUZERN**