

# Aktivitätsklassifizierung anhand von Sensordaten

Anwendung und Vergleich von Random Forest, KNN und DecisionTrees  
auf dem UCI HAR Datensatz

Oliver Schütz<sup>1,\*</sup> and Michael Graber<sup>2,\*</sup>

<sup>1,2</sup>*Fachhochschule Graubünden*

*\*E-Mail Adressen: oliver.schuetz@stud.fhgr.ch,  
michael.graber@stud.fhgr.ch*

8. Dezember 2024

## Zusammenfassung

Diese Arbeit untersucht die Zuverlässigkeit der Aktivitätserkennung anhand von Smartphone-Sensordaten des UCI Human Activity Recognition Datasets.

Nach einer Feature-Selection mittels Korrelationsanalyse wurden drei Klassifikationsverfahren (Decision Tree, KNN und Random Forest) trainiert und anhand des F1-Scores bewertet.

Random Forest und KNN lieferten durchschnittliche Ergebnisse, während der Decision Tree signifikant schlechter war. Damit zeigt sich, dass eine grundlegende Aktivitätserkennung möglich ist, jedoch noch Optimierungspotenzial hinsichtlich Modellwahl und Datenaufbereitung besteht.

## 1 Einleitung

Moderne Smartwatches wie die Apple Watch erkennen, ob sich der Träger bewegt und schlägt ein Workout vor, das es klassifiziert hat.

Aber auch Wearables wie Kopfhörer sind in der Lage zu erkennen, ob der Träger aufsteht und anfängt zu laufen.

Je nach Präferenz können die Kopfhörer dann z.B. den Noise canceling Mode verlassen.

Nicht jede\*r trägt eine Smartwatch oder ein anderes Wearable an sich, die allermeisten führen aber ein Smartphone mit sich.

Smartphones sind auch mit diversen Sensoren bestückt.

Allerdings variiert die Anzahl, Qualität und Art der verbauten Sensoren stark zwischen den Herstellern und deren Modellen und Preisklassen.

Daher stellt sich die Frage, ob die Daten für eine Vorhersage ausreichen.

## **2 Stand der Forschung**

Human Activity Recognition (HAR) ist der Versuch, anhand von Sensordaten die Aktivität einer Person zu bestimmen bzw. vorherzusagen (Brownlee, o. J.).

Hierzu werden oft Convolutional Neural Network (CNN) verwendet (Sikder, Chowdhury, Arif & Nahid, o. J.; Brownlee, o. J.), manchmal wird aber auch auf Machine Learning (Alagoz, o. J.) zurückgegriffen.

Ein allgemein beschriebenes Problem besteht darin, dass Menschen heterogene Aktivitäten ausführen und die Sensordaten sich selbst bei gleicher Aktivität und gleicher Sensorqualität unterscheiden können.

## **3 Forschungsfragen und Methodik**

Die Forschungsfrage besteht darin, wie zuverlässig können Aktivitäten anhand von Smartphone Sensordaten erkannt werden.

Als Basis dieser Analyse diente der Datensatz "UCI Human Activity Recognition (HAR) Dataset" (Jorge Reyes-Ortiz, o. J.). Dieser enthält Aktivitäten, gelabelt nach Sensordaten von Smartphones (Samsung Galaxy S II). Die Daten stammen von 30 Probanden im Alter von 19 bis 48 Jahren, die sechs vordefinierte Aktivitäten ausführten:

- WALKING (Gehen)
- WALKING\_UPSTAIRS (Treppe hinaufgehen)
- WALKING\_DOWNSTAIRS (Treppe hinuntergehen)
- SITTING (Sitzen)
- STANDING (Stehen)
- LAYING (Liegen)

Der Datensatz wurde bereits in einen Test und Trainingsset unterteilt, wobei das Trainingsset 70% und das Testset 30% der Daten enthält. Eine Datenaufbereitung war jedoch notwendig, da manche Features einen für Pandas DataFrame nicht eindeutigen Namen hatten. Beispielsweise wurden die folgenden zwei Features als identisch gewertet:

- fBodyGyro-bandsEnergy()-33,40
- fBodyGyro-bandsEnergy()-41,48

Da der Datensatz hunderte von Features enthält, wurde eine Feature Selection durchgeführt, um die Anzahl der Features zu reduzieren. Hierzu wurde die Korrelation jedes Features mit der Aktivität berechnet und die 20 Features mit der höchsten positiven und negativen Korrelation ausgewählt.

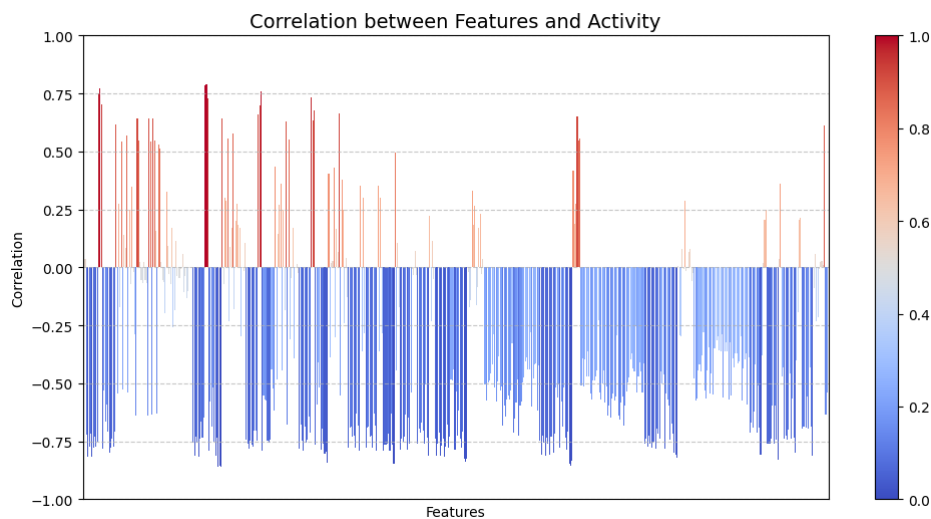


Abbildung 1: Korrelation der Features mit der Aktivität

Damit wurden 3 Modelle trainiert und mit dem F1-Score evaluiert:

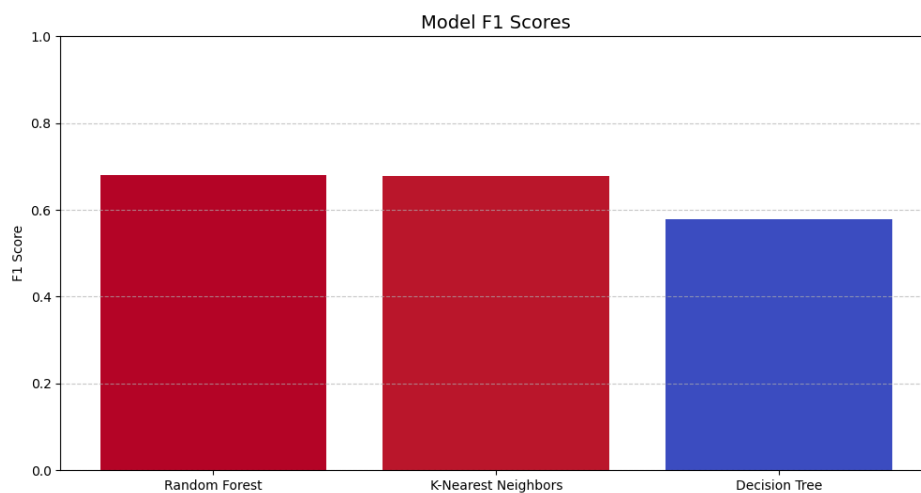


Abbildung 2: Modelle und deren F1-Score

## 4 Resultate

Mit den drei verwendeten Modellen lässt eine Vorhersage der Aktivitäten realisieren. Allerdings unterscheiden sie sich bei der Genauigkeit der Vorhersage.

Der Decision Tree schneidet mit einem F1-Score von 0,58 am schlechtesten ab, da er im Vergleich zu komplexeren Modellen wie dem Random Forest eher anfällig für Overfitting ist und weniger robuste Entscheidungsregeln bildet. Der Random Forest und KNN haben mit rund 0,68 einen ähnlichen F1-Score. Der Random Forest Algorithmus liefert durch die Kombination vieler Entscheidungsbäume stabilere Vorhersagen, der KNN-Algorithmus dagegen ist auch anfällig für Overfitting. Insgesamt liefert der Random Forest tendenziell die besten Ergebnisse.

## 5 Diskussion

Mit Deep Learning Algorithmen liessen sich eine Genauigkeit von bis zu 96% (Alagoz, o. J., p.402)(Brownlee, o. J.; Sikder et al., o. J.) erzielen.

Der nächste Schritt bestünde daher darin, die entsprechenden Modelle zu trainieren und Anzuwenden, um bessere Vorhersagen treffen zu können.

## Literatur

- Alagoz, C. (o.J.). *Comparative analysis of XGBoost and minirocket algorthims for human activity recognition* (Nr. arXiv:2402.18296). arXiv. Zugriff am 2024-12-01 auf <http://arxiv.org/abs/2402.18296> doi: 10.48550/arXiv.2402.18296
- Brownlee, J. (o. J.). *A gentle introduction to a standard human activity recognition problem*. Zugriff am 2024-12-01 auf <https://www.machinelearningmastery.com/how-to-load-and-explore-a-standard-human-activity-recognition-problem/>
- Jorge Reyes-Ortiz, D. A. (o. J.). *Human activity recognition using smartphones*. UCI Machine Learning Repository. Zugriff am 2024-12-08 auf <https://archive.ics.uci.edu/dataset/240> doi: 10.24432/C54S4K
- Sikder, N., Chowdhury, M. S., Arif, A. S. M. & Nahid, A.-A. (o.J.). *Human activity recognition using multichannel convolutional neural network* (Nr. arXiv:2101.06709). arXiv. Zugriff am 2024-12-01 auf <http://arxiv.org/abs/2101.06709> doi: 10.48550/arXiv.2101.06709