

(ab 9-14.12.24)

Sensordatenverarbeitung

BEWEGUNGSMERKMALE (9B)

Merkmale allgemeiner Sensordaten

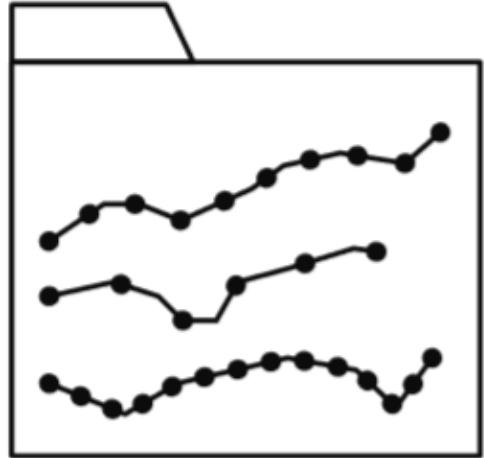
- Allgemeine Sensordaten

- Von Sensoren gemessene Größen für die es keine ausgearbeitete Sensordatenverarbeitungstheorie gibt
- „Einfach eine Kurve ohne Bedeutung“
- Oder auch als Startpunkt für sensorspezifische Verfahren
- Z.B. Temperatur, Länge (kontextabhängig), Helligkeit, Kraft (kontextabh.)

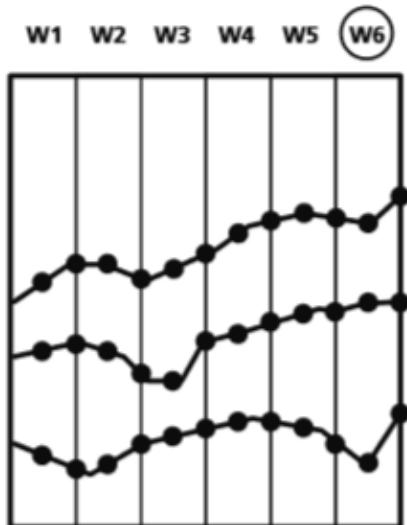
- Generelle Merkmale

- Berücksichtigen nicht spezifische Eigenschaften des Sensors
- Aus einem zeitlichen Ausschnitt des Signals berechnet (Sliding Window)
- Ggf. Rand weniger gewichten (Windowing Function)

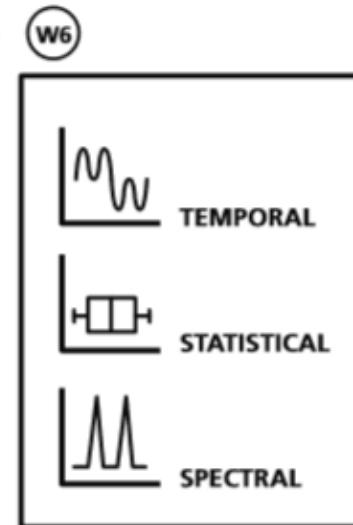
DATASET ANALYSIS



PREPROCESSING



WINDOW FEATURE EXTRACTION



OUTPUT

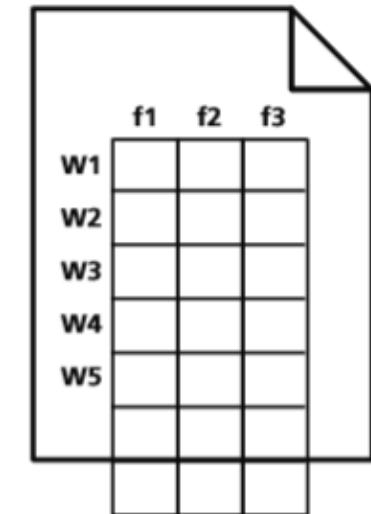


Diagram of the output feature matrix. It is a grid with 5 rows labeled W1 to W5 and 3 columns labeled f1, f2, and f3. The grid cells are empty, representing the feature values for each window and feature.

	f1	f2	f3
W1			
W2			
W3			
W4			
W5			

Marília Barandas, Duarte Folgado, Letícia Fernandes, Sara Santos, Mariana Abreu, Patrícia Bota, Hui Liu, Tanja Schultz, Hugo Gamboa, TSFEL: Time Series Feature Extraction Library, SoftwareX, Volume 11, 2020 (online frei verfügbar)

- Merkmale im Zeitbereich:
 - **Energie, Area under Curve**
 - **Maximum, Minimum, Absolute Differenzen, Steigung,**
 - Peak-to-Peak Distanz,
 - Autokorrelation,
 - Entropy,
 - **Zero-crossing Rate**
- (stat.) Verteilungs-Merkmale:
 - Verteilung: **Mittelwert, Median, Schiefe, Wölbung**
 - Verteilung: **Standardabweichung, Varianz, Kovarianz**
 - Histogramm
 - **Maximum, Minimum, Range, Quantile**
 - **Quadratisches Mittel** (Root Mean Square RMS)
- Merkmale im Spektralbereich:
 - Leistungsspektrum, Phase, MFCC Koeffizienten → VL 10
 - Linear Predictive Koeffizienten,
 - Wavelet

TSFEL library
frei verfügbar

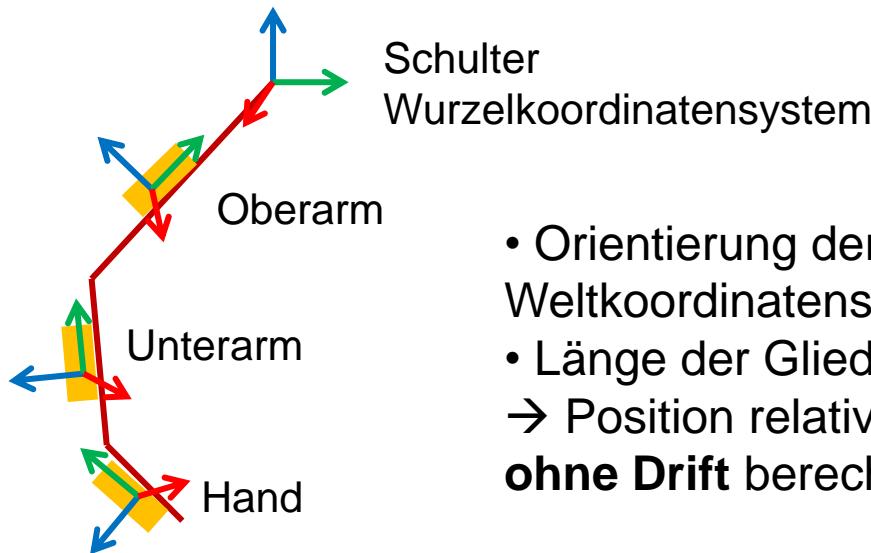
Bewegungsmerkmale



- VL 5: Beschleunigung \mathbf{a}_t und Drehrate $\boldsymbol{\omega}_t$ können zu Geschwindigkeit \mathbf{v}_t , Position \mathbf{p}_t und Orientierung \mathbf{R}_t aufintegriert werden
- Aus welchen dieser Daten sollte man Merkmale berechnen?
- Rohe Sensordaten $\mathbf{a}_t, \boldsymbol{\omega}_t$:
 - Häufigste Wahl
 - Gut für Erkennung kurzer Bewegungen (z.B. Gesten)
- Orientierung \mathbf{R}_t :
 - “Wo ist unten?” ($-\mathbf{R}_t^{-1}\mathbf{e}_3$) mit geeignetem Sensorfusionsalgorithmus dauerhaft genau. Sinnvoll für Neigung von Objekten / Haltung von Menschen
 - Rest (Drehung um Z) driftet (typisch $0.1^\circ/\text{s}$)
 - → anwendungsspezifische Gegenmaßnahmen, Relativorientierung in einen Zeitintervall nutzen oder nicht verwenden
- Geschwindigkeit \mathbf{v}_t , Position \mathbf{p}_t :
 - Driftet schnell (typisch 0.1m/s^2)
 - Nur mit speziellen „Tricks“ zu verwenden



- Platziere Sensoren an allen Gliedmaßen eines Menschen / Roboter
- Benutze Sensorfusion um Orientierung im Raum für jeden Sensor zu bestimmen
- Berechne Position der Gliedmaßen über Vorwärts-Kinematik relativ zum Wurzelgelenk
- Beispiel Arm:

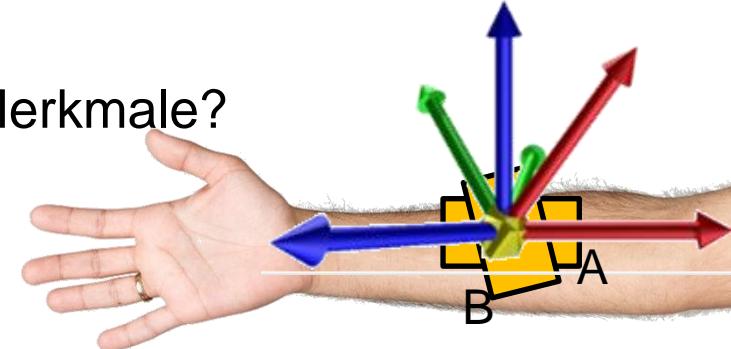


- Orientierung der 3 Sensoren im globalen Weltkoordinatensystem bekannt
- Länge der Gliedmaßen bekannt
- Position relativ zur Schulter kann **ohne Drift** berechnet werden

- Aus den ausgewählten Daten einige der unter „allgemeine Merkmale“ gelisteten Merkmale in Zeitfenster berechnen

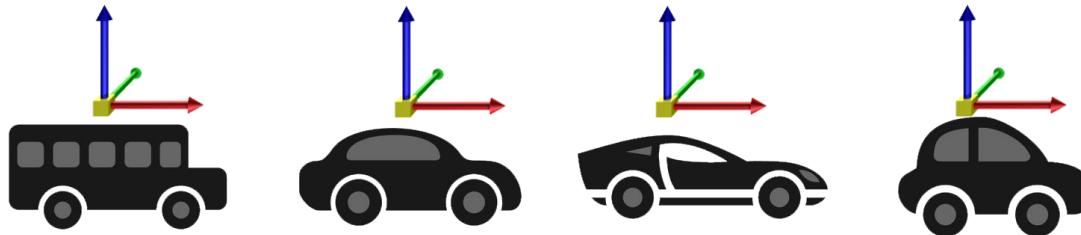


- Welchen Einfluss hat die Orientierung des Inertialsensors auf die Daten?
 - Zwei IMUs A, B an selber Position mit verschiedener Orientierung
 - Koordinatentransformation $R_{B \leftarrow A}$ der vektoriellen Messwerte
 - $\omega^{Bt} = R_{B \leftarrow A} \omega^{At}$
 - $a^{Bt} = R_{B \leftarrow A} a^{At}$
- Welchen Einfluss hat die Orientierung auf Merkmale?
- Invariante Merkmale ändern sich nicht
 - Norm: $\|\omega_t\|$ oder $\|a_t\|$
 - mittlere Norm, Varianz der Norm, etc.
 - über 3 Koordinaten summierte Energie in STFT
- Sog. kovariante Merkmale unterliegen der selben Transformation
 - Mittelwert, Kovarianzmatrix
 - STFT
- Viele Merkmale ändern sich unkontrolliert
 - Min, Max, Varianz / Std.-Abweichung, Anzahl Nulldurchgänge

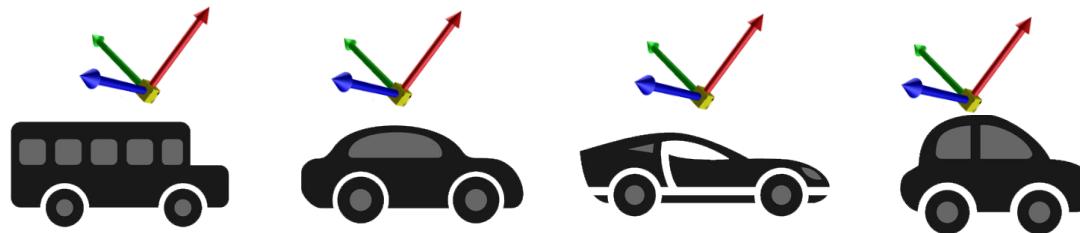


- Fest → gleich für alle Trainingsdaten und die Anwendung
- Sinntragend → Achsen haben Bedeutung, z.B. Z=oben, X=vorne, etc.
- Für praktikable Montage sorgen, 180°-Dreher ausschließen
- In/kovariante Merkmale nutzen
- Nicht in-/kovariante Merkmale können besonders gut sein

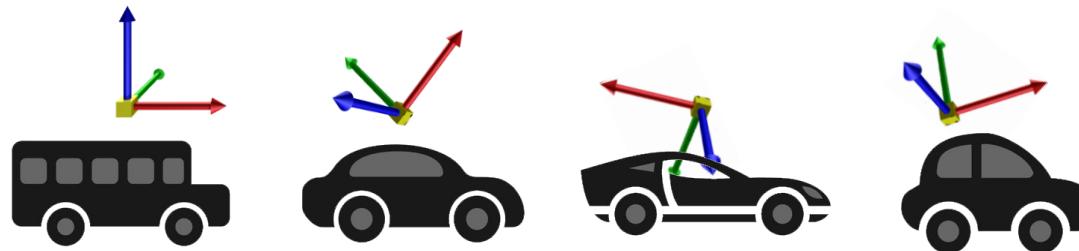
- Illustratives Beispiel: Manövererkennung für KfZ
 - Verschiedene Autos in Trainingsdaten bzw. Anwendung
 - Wie die IMU montiert ist



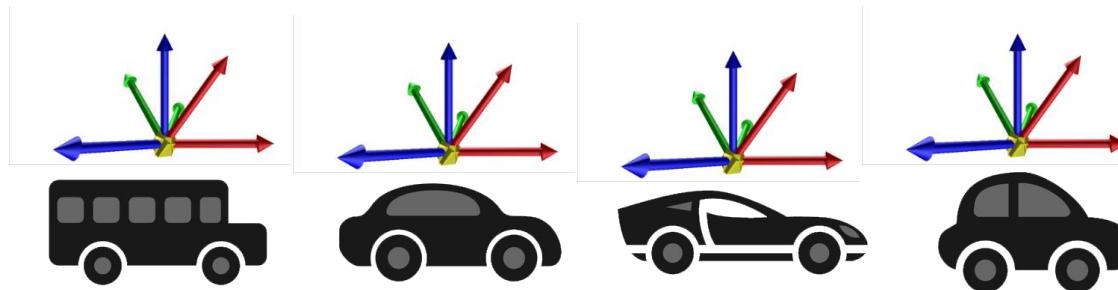
- (Fast) alle Klassifizierer können lineare Transformation mitlernen
- In-/kovariante Merkmale nutzen
- Nutzen nicht in-/kovarianter Merkmale unklar



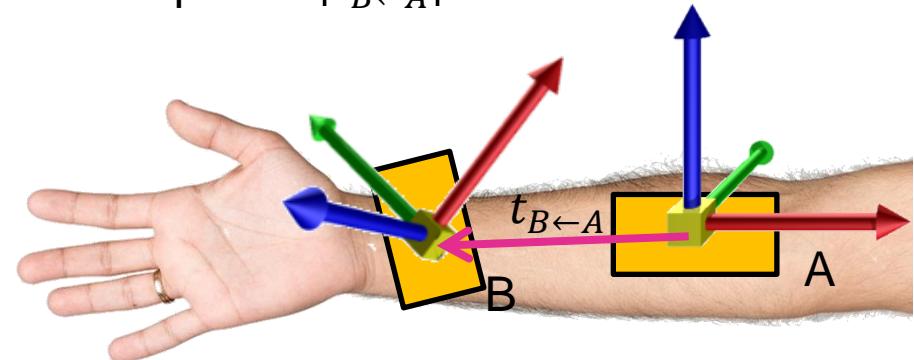
- Orientierung ändert sich zwischen Nutzungen
- Z.B. jeweils etwas andere Fixierung an Objekten / Probanden
- Invariante Merkmale nutzen
- Kovariante Merkmale mit Vorverarbeitung
 - umrechnen in ein Standardkoordinatensystem
 - Z nach oben durch Orientierungsschätzer (einfach)
 - X nach vorne (schwierig: anwendungsspezifische Heuristik nötig)



- Orientierung ändert sich während der Nutzung
- Z.B. Verrutschen der Halterung
- Möglichst vermeiden
- Invariante Merkmale nutzen
- Projektion in vertikale Richtung gemäß Orientierungsschätzer nutzen



- Welchen Einfluss hat die Position des Inertialsensors auf die Daten?
 - zwei IMUs A, B an verschiedener Position und Orientierung
 - Koordinatentransformation + Zusatzbeschleunigung
 - $\omega_{Bt} = R_{B \leftarrow A} \omega_{At}$
 - $a_{Bt} = R_{B \leftarrow A} a_{At} + \dot{\omega}_{At} \times t_{B \leftarrow A} + \omega_{At} \times (\omega_{At} \times t_{B \leftarrow A})$
- Position beeinflusst nicht ω
- Wie wichtig ist die Position für a?
 - hängt stark von $\omega, \dot{\omega}$ ab
 - obere Schranke des Einflusses: $(|\dot{\omega}_{At}| + |\omega_{At}|^2) |t_{B \leftarrow A}|$ (ω in Radian/s)
 - Vorgehen: Werte für $\omega, \dot{\omega}$ schätzen und akzeptable $|t_{B \leftarrow A}|$ ausrechnen.



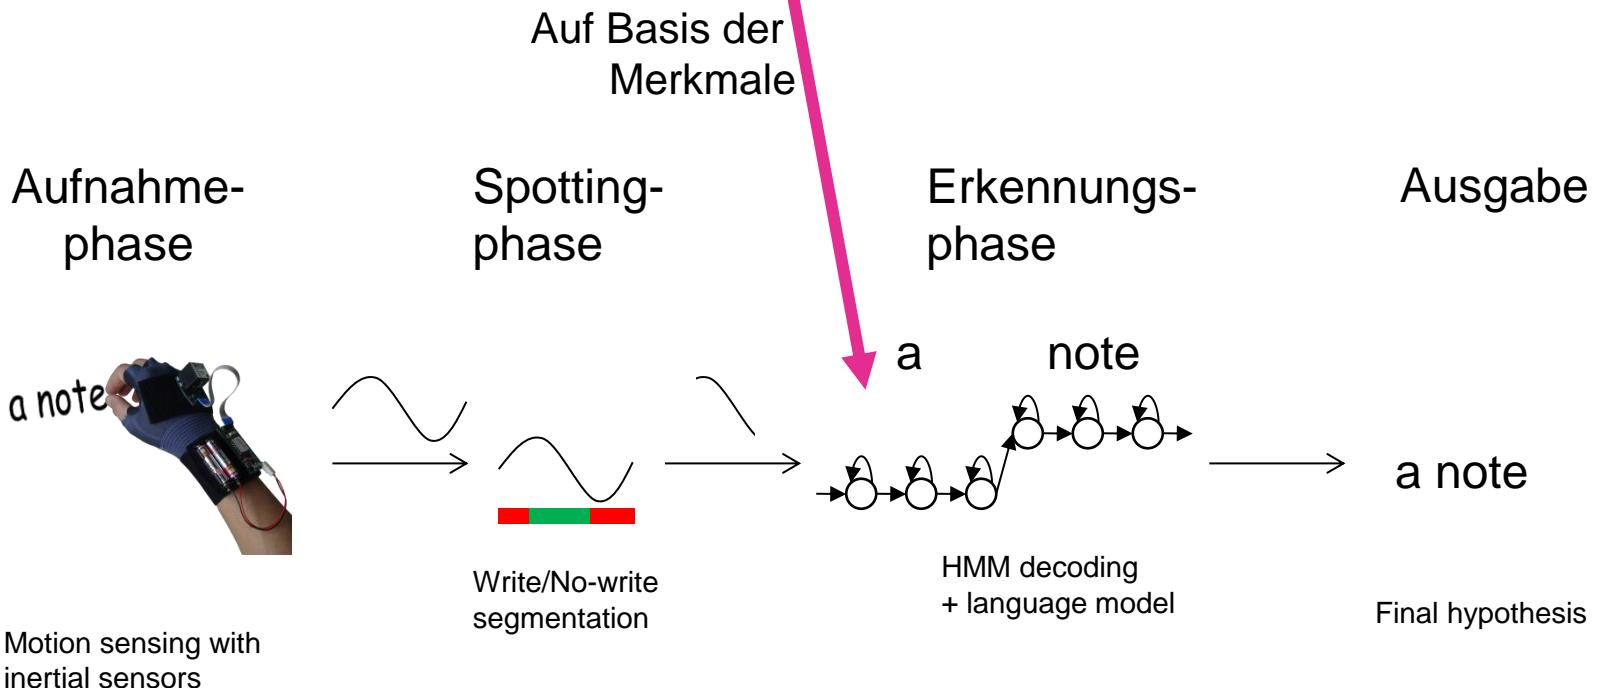
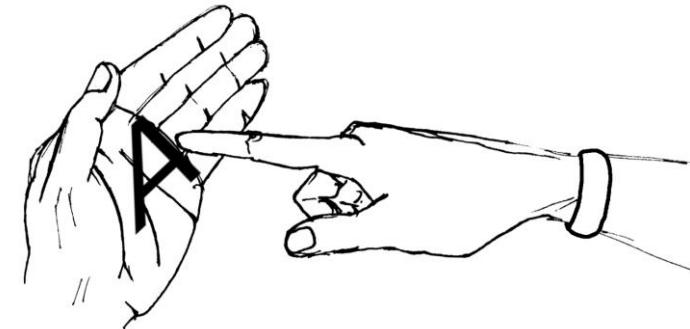
- Beispielrechnungen für ein Gefühl für den Effekt
- Beispiel 1: Auto durchfährt Kurve
 - Auto fährt mit 30km/h durch Kurve mit 10m Radius
 - Der Übergang zur Geraden ist 5m lang
 - $\omega = \frac{0.8 \text{ rad}}{\text{s}}, \dot{\omega} = \frac{1.38 \text{ rad}}{\text{s}^2}, (|\dot{\omega}| + |\omega|^2) = \frac{2.08}{\text{s}^2},$
 - 0.1m Fehler führt zu 0.2m/s² Fehler → unkritisch
- Beispiel 2: 100m Lauf, IMU am Bein
 - Usain Bolt sprintet mit $v=100\text{m}/9.72\text{s}$ und Beinlänge $r=1.1\text{m}$,
 - $\omega = \frac{v}{r} \approx 9.35 \frac{\text{rad}}{\text{s}}$ beim Bodenkontakt.
 - Er macht $c=4.28$ Schritte/s, näherungsweise ist $\dot{\omega} = 2\omega c \approx 80 \frac{\text{rad}}{\text{s}^2}$
 - $(|\dot{\omega}| + |\omega|^2) \approx \frac{167}{\text{s}^2}$.
 - 1mm Fehler führt zu 0.16m/s² Fehler → kritisch
 - Quelle: https://de.wikipedia.org/wiki/Usain_Bolt



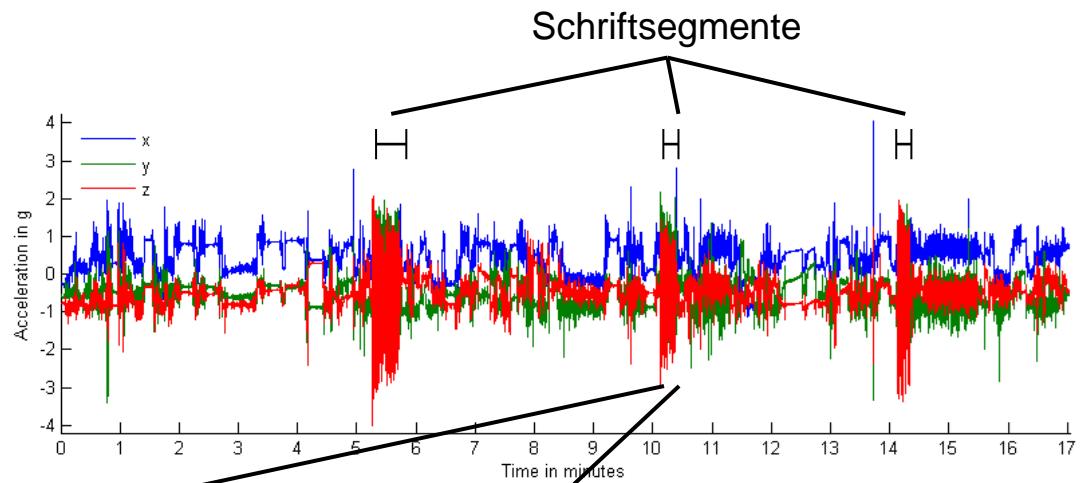
- Extraktion von Merkmalen: Beispiele aus der Praxis

Beispiel: Airwriting

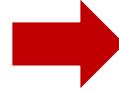
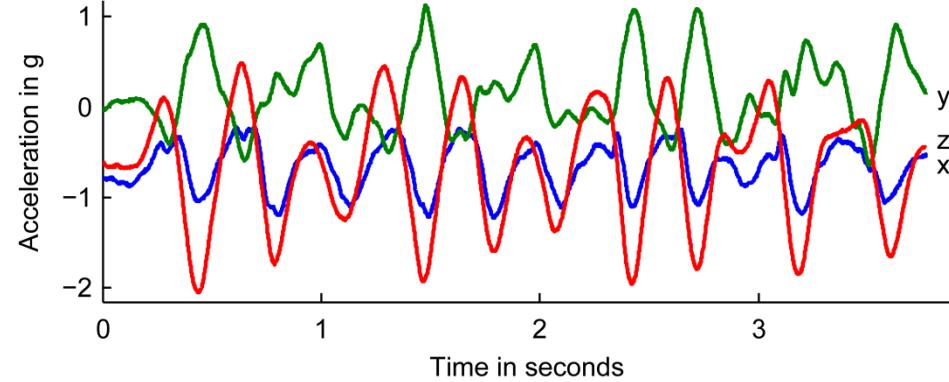
- Erkennung von 3D Handschrift in der Luft
 - Inertialsensoren an der Hand/Handgelenk
 - Messdatenübertragung per Bluetooth
 - Detektion mit Token Modeling (SVM)
 - Erkennung mit Sequenzmodellierung (HMM)



Airwriting: Detektion und Erkennung



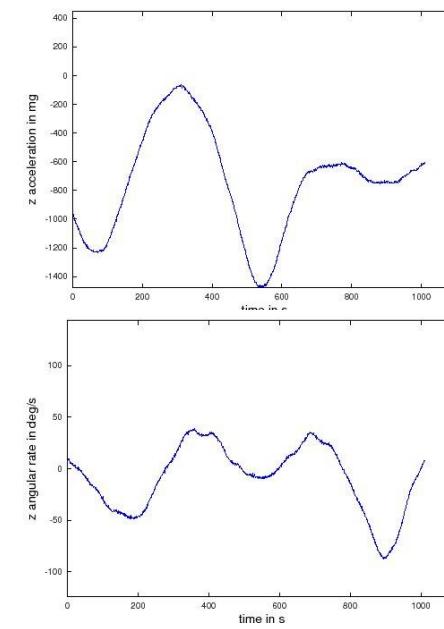
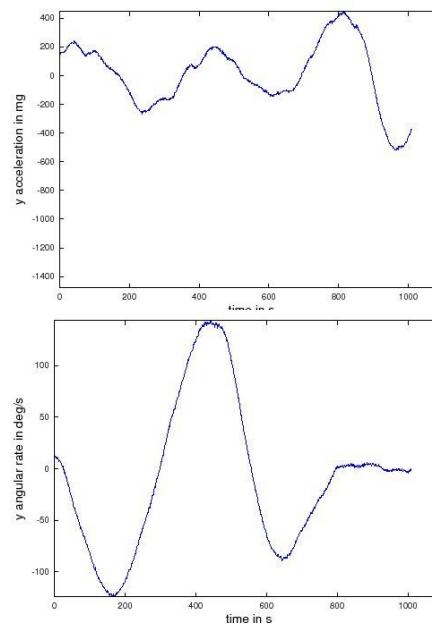
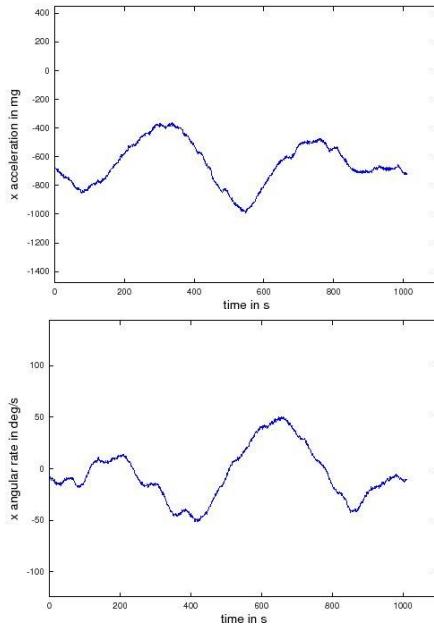
Schriftsegmente



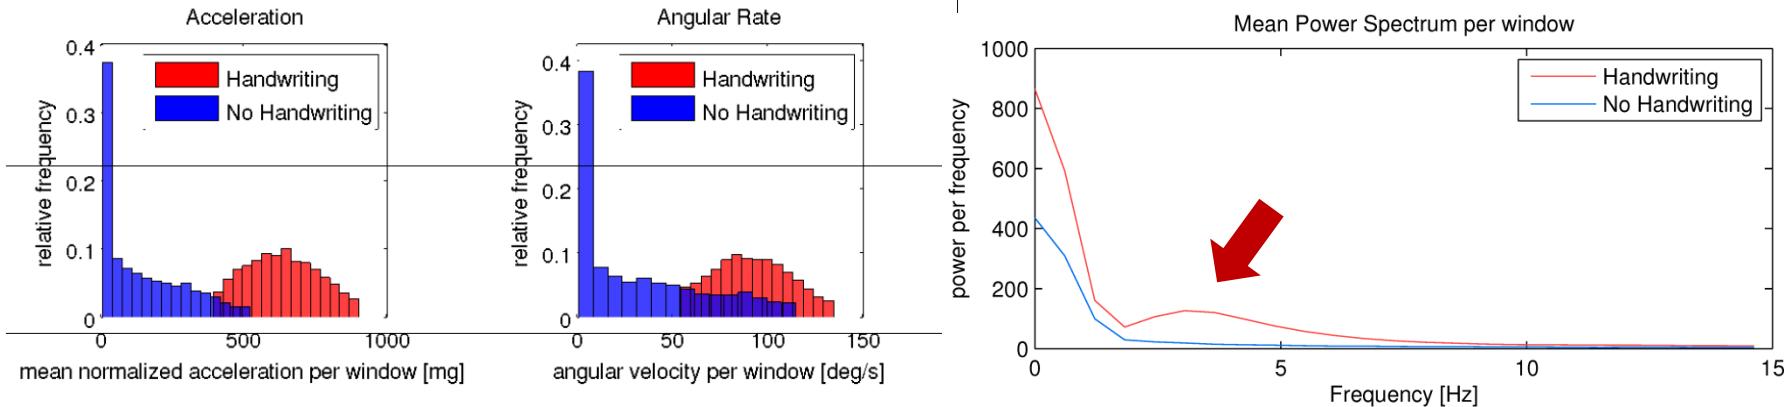
HAND

Trägheitsbasierte Erfassung: Signale

- Signalbeispiel für Buchstaben A mit Sensor auf Handrücken in die Luft geschrieben
- Signale haben geringen Rauschanteil
- Sensororientierung unterscheidet sich von Referenzsystem
 - Daher keine intuitive Vorstellung der ausgeführten Bewegung möglich
- Einfluß der Gravitation in x und z Richtung deutlich sichtbar



Datenanalyse:



Wähle folgende Merkmale :

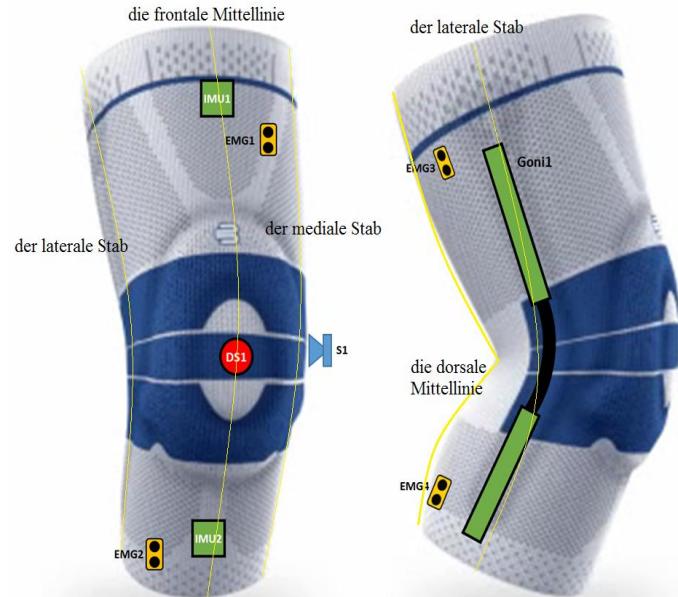
- durchschnittliche Winkelgeschwindigkeit
- durchschnittliche normalisierte Beschleunigung
- Verteilung der Frequenzenergie (0-12Hz)

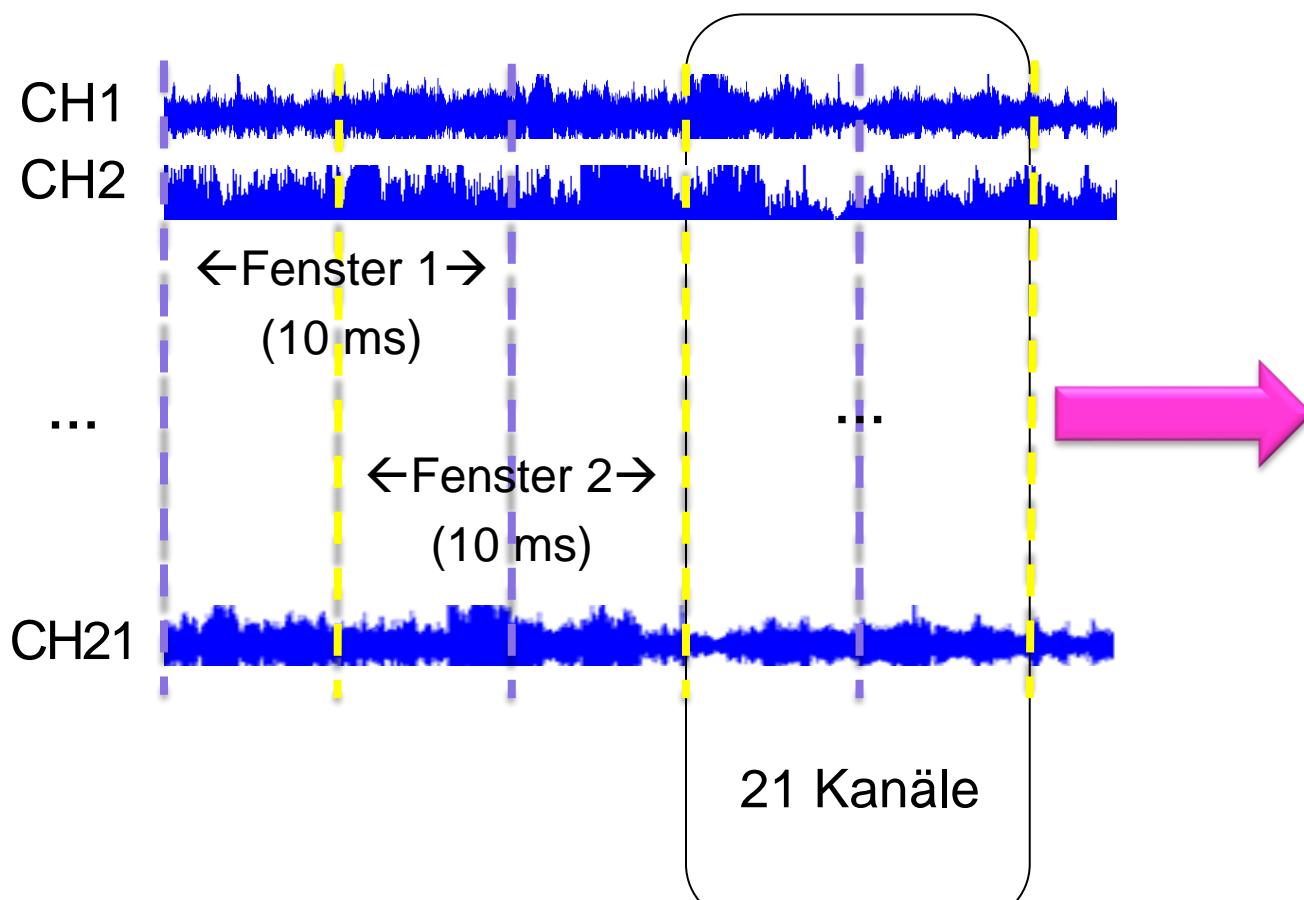
Schrift hat einen Peak bei ~ 3Hz

- 3 Plux Hubs je 8 Kanäle
 - Synchronisation mit Kabeln vom Plux Sync Toolkit

- 12 Sensoren
 - 4 x EMG
 - 1 x 2D-Goniometer
 - 2 x 3-Achsen Beschleunigungssensoren
 - 2 x 3-Achsen Gyroskope
 - 1 x Airborne (Akustisches) Mikrofon
 - 1 x Piezoelektrisches Mikrofon
 - 1 x Drucksensor

- 22 Kanäle verwendet
 - 21 Signalkanäle (4 EMG + 2 Gonio + 6 ACC + 6 Gyro + 2 Mik + 1 Druck)
 - 1 Pushbuttonkanal für Annotation und automatische Segmentierung





21-dim. Merkmalsvektor

$$\sqrt{\sum_{i=0}^9 E_{0i}^2} : \text{EMG1}$$

$$\sqrt{\sum_{i=0}^9 E_{1i}^2} : \text{EMG2}$$

$$\sqrt{\sum_{i=0}^9 E_{2i}^2} : \text{EMG3}$$

$$\sqrt{\sum_{i=0}^9 E_{3i}^2} : \text{EMG4}$$

$$\sqrt{\sum_{i=0}^9 x_{0i}} : \text{Acc upper X-axis}$$

$$\sqrt{\sum_{i=0}^9 y_{0i}} : \text{Acc upper Y-axis}$$

$$\sqrt{\sum_{i=0}^9 z_{0i}} : \text{Acc upper Z-Axis}$$

.....

$$\sqrt{\sum_{i=0}^9 G_{0i}} : \text{Goniometer frontal}$$

$$\sqrt{\sum_{i=0}^9 G_{1i}} : \text{Goniometer sagittal}$$

$$\sqrt{\sum_{i=0}^9 A_{0i}} : \text{Airborne Mikrofon}$$

$$\sqrt{\sum_{i=0}^9 P_{0i}} : \text{Piezo Mikrofon}$$

Schematische Darstellung der Fensterung und Merkmalsextraktion

- 3D-Beschleunigungssensoren

- Durchschnittswert: $avg(x) = \frac{1}{N} \sum_{k=1}^N x_k$
- Korrelation: $corr(x, y) = \frac{cov(x, y)}{\sigma_x \sigma_y} = \frac{E((x - E(x))(y - E(y)))}{\sqrt{var(x)} \sqrt{var(y)}}$
- Empirische Verteilungsfunktion: $P_{ECDF}(x) = P(X \leq x)$

- EMG

- Quadratisches Mittel: $rms(x) = \sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2}$
- Integrierte EMG: $iEMG(x) = \sum_{k=1}^N |x_k|$
- Empirische Verteilungsfunktion

- Goniometer

- Empirische Verteilungsfunktion

- Normalisierung

- Allgemeine Merkmale
 - Energie, Area under Curve, Maximum/Minimum, Steigung, Zero-crossing Rate, Mittelwert, Standardabweichung, Varianz, Quadratisches Mittel
 - Von einem mitlaufenden Fenster (Sliding Window) berechnet
- Bewegungsmerkmale
 - Allgemeine Merkmale der Beschleunigung a_t und Drehrate ω_t (ggf. Orientierung R_t)
 - Orientierung der IMU beachten (ideal: fest und sinntragend)
 - Position der IMU weniger kritisch

- Ausgestreckter Arm eines Mannes, Von Genusfotografen (genusfotografen.se) & Wikimedia Sverige (wikimedia.se), CC BY-SA 4.0, <https://commons.wikimedia.org/w/index.php?curid=50355953>
- orcjuly, Auto-Icon-Set, 123rf.com, # 32600841,
- Marília Barandas, Duarte Folgado, Letícia Fernandes, Sara Santos, Mariana Abreu, Patrícia Bota, Hui Liu, Tanja Schultz, Hugo Gamboa, TSFEL: Time Series Feature Extraction Library, SoftwareX, Volume 11, 2020 (online frei verfügbar)
- Stable Diffusion "everyday car driving through turn"
- Erik van Leeuwen, 100 metre final at 2015 World Championships in Athletics, GFDL,
https://de.wikipedia.org/wiki/Usain_Bolt#/media/Datei:100_m_final_at_2015_World_Championships_in_Athletics_Beijing_1.jpg