

Untersuchung zum Einsatz von Methoden des Transfer Learning für die ultraschallbasierte Objektklassifikation mit Neuronalen Netzen

Heiko Raible^{1,2}, Prof. Ing. André Gerlach¹, M. Eng. Jona Eisele¹, Prof. Dr. Andreas Thümmel²

1) Robert Bosch GmbH, Forschungscampus Renningen, CR/AME1

2) Hochschule Darmstadt, FBMN & FBI

1 Einleitung

- **Automatisiertes Fahren** und **Fahrerassistenzsysteme** erfordern verbesserte Erfassung der Fahrzeugumgebung in unmittelbarer Nähe.
- **Ultraschallsensoren** ermöglichen **Park-** und **Manövrierfunktionen**
- Derzeit: Entfernungsmessung zu Hindernissen.
- Ziel: **Klassifikation von Hindernissen** anhand von Ultraschallechos
- Fokus: Anwendung von **Transfer Learning** Methoden für einen Wissenstransfer zwischen **Sensoranordnungen**

2 Datenerfassung

- **Reflexionsarmer Messraum**
- **Portalroboter** zur relativen Ausrichtung
- Diverse **Sensoranordnungen**
- **Stand** und **Fahrt** Messungen
- Sender: Bosch USS6 (42,5–53,5 kHz Chirp)
- Empfänger: Kondensatormikrofon (200 kSa/s)
- Messungen von **55 Objekten** in jeweils **55 Positionen**
- **Objektweise** Trainings- / Testdatensplits



Abb. 1: Messung eines Rohres mit Portalroboter

3 Signalverarbeitung

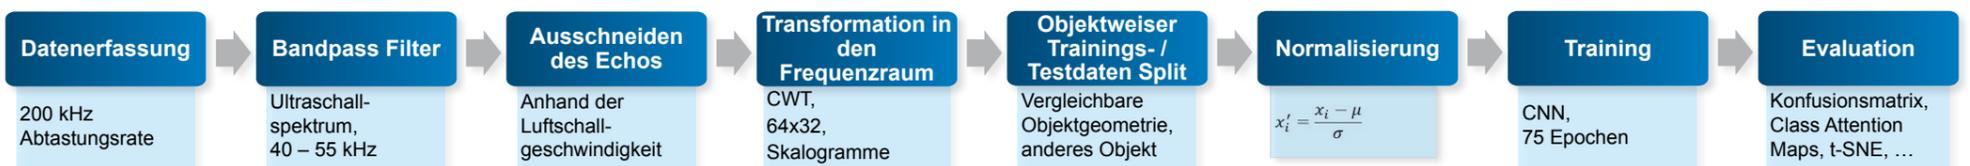


Abb. 2: Signalverarbeitung

- Features zur Unterscheidung von Objekten basieren auf der **zeitlichen** und **spektralen** Struktur von akustischen Echos.
- **Objektrückstreuung** wird anhand Distanz von Objekt zu Sensor und Luftschallgeschwindigkeit ausgeschnitten.
- Die **kontinuierliche Wavelet-Transformation (CWT)** extrahiert Zeit-Frequenz-Bilder (**Skalogramme**).
- Ein **Convolutional Neural Network (CNN)** wird mit (a) **Zeit-Frequenz-Bildern** und (b) **Distanzen** als Eingabe verwendet.

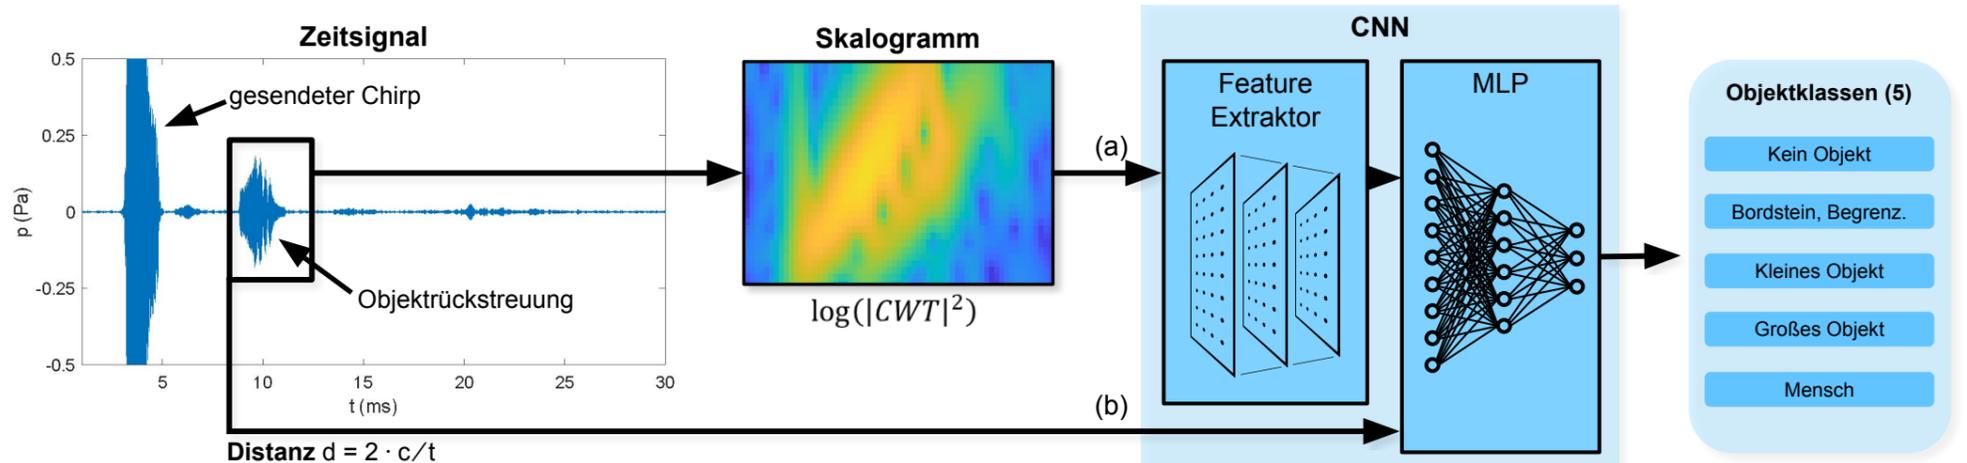


Abb. 3: Kombination der Features und Distanzen zur Klassifikation

4 Transfer Learning

Fine-Tuning:

- Modelle können effektiv an neue Sensoranordnungen angepasst werden
- Höhenversatz eines Sensors hat keine signifikante Auswirkung

Vortraining mit Audio Daten:

- Verbessert Leistung
- Freezing führt zu Verlusten

Domänenannäherung der Daten unterschiedlicher Sensoranordnungen:

- Erzielt Leistungssteigerung in Untersuchungen ohne Fine-Tuning auf die Zielsensoranordnungen

Modell	#Transfers	Stand (%)	Fahrt (%)	Gesamt (%)
BEATs (freeze)	0 (+AudioSet)	68.13	56.63	62.38
BEATs (freeze)	1 (+AudioSet)	69.97	56.41	63.19
BEATs (freeze)	2 (+AudioSet)	71.11	57.45	64.28
Base Model	0	82.77	81.71	82.24
Base Model	1	84.23	82.78	83.50
Base Model	2	85.10	83.04	84.07
EfficientAT	0	75.88	75.18	75.53
EfficientAT	0 (+AudioSet)	78.64	78.18	78.41
EfficientAT	1	80.26	79.00	79.63
EfficientAT	1 (+AudioSet)	82.08	80.42	81.25
EfficientAT	2	81.44	79.57	80.50
EfficientAT	2 (+AudioSet)	83.67	81.67	82.67
YAMNet	0	81.28	80.98	81.13
YAMNet	0 (+AudioSet)	81.20	81.23	81.22
YAMNet	1	83.81	82.50	83.16
YAMNet	1 (+AudioSet)	83.15	81.94	82.55
YAMNet	2	83.82	83.18	83.50
YAMNet	2 (+AudioSet)	83.51	82.62	83.06

Tab. 1: Ergebnisse diverser Modelle unter Angabe der Anzahl Transfers. Höchstleistung je Spalte hervorgehoben.

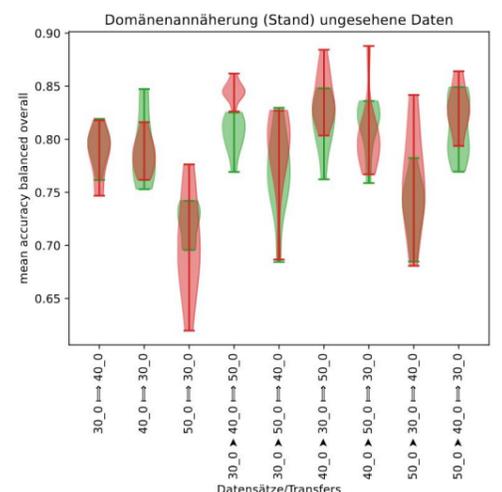


Abb. 4: Vergleich mit (rot) und ohne (grün) Domänenannäherung auf ungesehenen Daten

Leistungsgewinne im Fine-Tuning zwischen Sensoranordnungen sind auf eine erhöhte Datenmenge zurückzuführen.