Machine Learning basierte Klassifikation von Außenschallszenen für Lärmmessungen an Windenergieanlagen

Nils Poschadel[1], Christian Gill[1], Stephan Preihs[1], Susanne Martens[2], Jakob Bergner[1], Raimund Rolfes[2] und Jürgen Peissig[1]

[1] *Leibniz Universität Hannover, Institut für Kommunikationstechnik*

[2] *Leibniz Universität Hannover, Institut für Statik und Dynamik*

Appelstr. 9A, 30167 Hannover, Email: poschadel@ikt.uni-hannover.de

Abstract

Im Rahmen des interdisziplinären Projektes WEA-Akzeptanz werden an der Leibniz Universität Hannover Messungen der Schallemission von Windenergieanlagen durchgeführt. Durch die Umgebung, das Wetter oder die Vegetation kommt es zu Störkomponenten (Wind, Regen, Vogelgezwitscher, Verkehr, ...) in den aufgenommenen Signalen, welche einen Einfluss auf die nachgeschalteten Signalauswertungen haben können. Aufgrund der Menge an Daten ist eine händische Identifikation der ungestörten Audiosignale nicht praktikabel, sodass eine automatisierte Klassifizierung der Störgeräusche erforderlich ist.
In diesem Beitrag wird der Messaufbau, die Methodik zur Klassifikation sowie eine Evaluation der Klassifikationsergebnisse auf Basis verschiedener Metriken vorgestellt. Die Ergebnisse zeigen, dass eine Machine Learning basierte Klassifizierung von Außenschallszenen mit mehr als 10 unterschiedlichen Klassen grundsätzlich möglich ist.

Einleitung

Schallmessungen an Windenergieanlagen finden im Rahmen von Abnahmemessungen und Schallgutachten in der Regel nur für kurze Zeiträume und an definierten Messpunkten statt. Im Zuge des Projektes WEA-Akzeptanz [3] werden jedoch auch Langzeitmessungen parallel an mehreren verteilten und unabhängigen Messstationen durchgeführt. Hierbei erfolgt neben der Messung von Oktavspektren auch die Aufnahme von unverarbeiteten Mikrofonsignalen. Durch dieses Vorgehen entstehen Datensätze mit mehreren Tausend Stunden an Audiomaterial, welche im Nachhinein weiterverarbeitet und analysiert werden müssen. In diesem Zusammenhang ergibt sich immer wieder das Problem, dass etwaige Störgeräusche in den Audioaufnahmen nach Möglichkeit nicht in Berechnungen oder Modellbildungen einfließen sollten. Demnach ist es wünschenswert, sich im Vorfeld automatisiert einen Überblick über die Anteile und Arten der Störgeräusche verschaffen zu können.

Messaufbau

Die in diesem Paper verwendeten Audiodaten wurden über einem Zeitraum von acht Wochen (4.6.2018-26.7.2018) mit voller Audiobandbreite (Samplingfrequenz 51,2 kHz) aufgenommen. Dazu wurden drei 01dB DUO inkl. Primär- und Sekundärwindschirm im (horizontalen) Abstand von 154 m, 249 m bzw. 479 m zu einer Windenergieanlage mit Getriebe der 3 MW-Klasse positioniert. Ein Überblick über den Messaufbau und die verwendeten Mikrofone ist in Abbildung 1 zu sehen. Neben den Audiodaten wurden zudem Metadaten wie Anlagenparameter und meteorologische Messdaten erhoben.

Abbildung 1: Beispiel der akustischen Messstation zur Langzeit-Aufnahme der Emissions-Zeitsignale von Windenergieanlagen (links, [3]) auf Basis des 01dB DUO (rechts).

Methodik zur Klassifikation

Zur Umsetzung der Mutli-Klassen-Klassifikation wurde ein auf Transfer Learning bzw. Fine-Tuning basierender Ansatz verwendet. Die möglichen Klassen lauten: Aircraft, Bell, Bird, Cricket, Rain, Silence, Thunder, Traffic, Wind und Wind Turbine. Zunächst wurde ein Convolutional Neural Network (CNN) entsprechend Tabelle 1 auf öffentlich verfügbaren Audiodaten der verschiedenen Klassen trainiert. Die Audiodaten wurden dafür einem Resampling auf 48 kHz unterzogen und in Fenster von 0.5 s aufgeteilt; als Input Features dienten Mel-Spektrogramme. Anschließend wurden einige Schichten des trainierten Netzes eingefroren und auf gelabelten Originaldaten der Messkampagne weitertrainiert (vgl. [1]). Das Training wurde mithilfe des Deep Learning Frameworks TensorFlow durchgeführt [2].

Evaluation der Klassifikationsergebnisse

Die Klassifikationsergebnisse wurden anhand von zwei verschiedenen Ansätzen evaluiert. Zunächst wurde das gelernte Modell klassisch auf einem dem Modell unbekannten Testdatensatz ausgewertet. Die Konfusionsmatrix dieser Auswertung ist in Abbildung 2 dargestellt. Dabei sind auf der Abszissenachse die prädizierten und auf der Ordinatenachse die tatsächlichen Klassenlabel aufgetragen. Beispielsweise wurden 92 % aller mit dem Label

Block	Eigenschaften	Dimension
Input	Mel-Spektrogramm	(128, 47, 1)
Conv2D MaxPooling	(3, 3) (4, 2)	(31, 22, 32)
Conv2D BatchNorm	(3, 3)	(29, 20, 64)
Conv2D MaxPooling	(5, 5) (4, 2)	(6, 8, 64)
Conv2D BatchNorm	(5, 5)	(2, 4, 128)
Flatten		(1024)
Dropout Dense	0.3 ReLU	(64)
Dropout Dense	0.3 softmax	(10)

Tabelle 1: Architektur des verwendeten CNNs zur Schallszenenklassifikation.

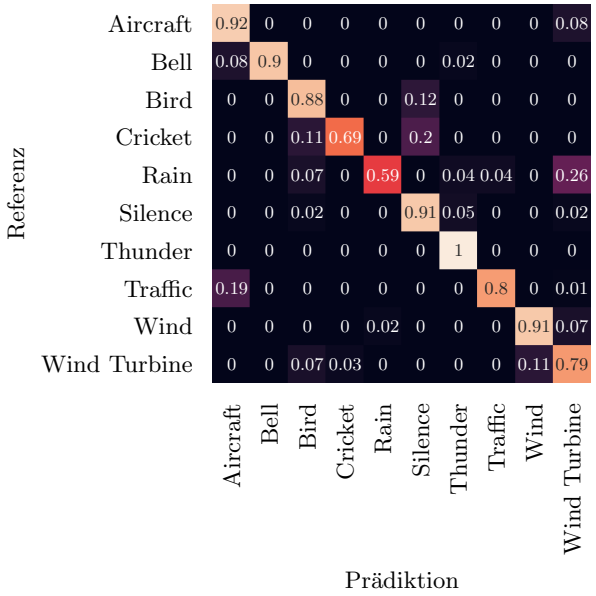

Abbildung 2: Konfusionsmatrix der Klassifikationsergebnisse auf einem Testdatensatz.

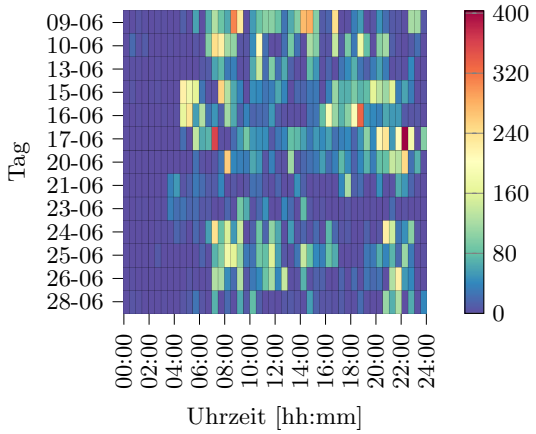

Abbildung 3: Klassifikationsergebnisse der Klasse Aircraft an verschiedenen Tagen. Die Farbcodierung entspricht der Anzahl an Klassifikationen der Klasse Aircraft pro 30 Minuten (max. 3600 möglich).

Aircraft versehenen Audio-Dateien als Aircraft und 8 % als Wind Turbine klassifiziert. Man erkennt, dass acht von zehn Klassen mit einer Klassifikationsrate von ca. 80 % korrekt klassifiziert worden sind. Lediglich die Klassen Cricket und Rain wurden mit 69 % bzw. 59 % schlechter klassifiziert.

Die falschen Klassifikationen der Klasse Cricket als Bird (11 %) und Silence (20 %) sind evtl. dadurch zu erklären, dass sich einerseits Vögel und Grillen auf den Aufnahmen durch ein sehr ähnliches, hochfrequentes Geräusch auszeichnen. Andererseits sind auf einigen Aufnahmen, die durch manuelles Labeling der Klasse Silence zugeordnet wurden, teilweise auch leise Vogel- bzw. Grillengeräusche zu vernehmen.

Analog sind womöglich einige Vertauschungen der Klassen Wind und Wind Turbine zu begründen. Die hohe Anzahl an Fehlklassifikationen der Klasse Rain als Wind Turbine ist hingegen nicht ohne Weiteres erklärbar.

Des Weiteren wurden die Klassifikationsergebnisse verschiedenen Plausibilitätstests unterzogen. Dabei ist anzumerken, dass die dargestellten Tests und Abbildungen nicht repräsentativ für alle Szenarien sind und es auch Konstellationen geben kann, die andere oder weniger plausible Ergebnisse liefern.

In einer ersten Untersuchung wurden die Klassifikationsergebnisse unterschiedlicher Tage miteinander verglichen. Abbildung 3 zeigt exemplarisch die Anzahl der positiven Klassifikationen der Klasse Aircraft pro 30 Minuten an 13 verschiedenen Tagen. Die Anzahl der Klassifikationen pro Zeitabschnitt (hier 30 Minuten) ist dabei als Farbcodierung dargestellt. Wie in diesem Szenario zu erwarten ist, werden nachts weniger bis keine Flugzeuge klassifiziert.

Die Abbildungen 4 und 5 zeigen die Häufigkeit an Klassifikationen der verschiedenen Klassen pro Minute über den Zeitraum von einer Stunde und die entsprechenden Metadaten desselben Zeitraums. Als Metadaten sind Wirkleistung und die Getriebedrehzahl der Anlage sowie die Windgeschwindigkeit und die sog. relative Windrichtung dargestellt. Eine relative Windrichtung von 0° bedeutet dabei, dass sich das Mikrofon genau im Nachlauf der Anlage befindet.

In Abbildung 4 sind die Klassifikationsergebnisse und Metadaten des 21.06.2018 von 08:00 bis 09:00 Uhr dargestellt. Der Tag wurde gezielt zur Auswertung ausgewählt, da dieser laut WetterKontor [4] mit einem Niederschlag von $20,4\,\frac{l}{m^2}$ an einem nahe gelegenen Flughafen der niederschlagreichste Tag des gesamten Messzeitraums war. Die hohe Anzahl an Klassifikationen der Klasse Rain ist deutlich zu erkennen, insbesondere in Phasen, in denen die Windenergieanlage eine geringere Wirkleistung/Getriebedrehzahl hat (ca. 08:10 bis 08:25 Uhr und 08:50 bis 09:00 Uhr). Die Klassifikationen der

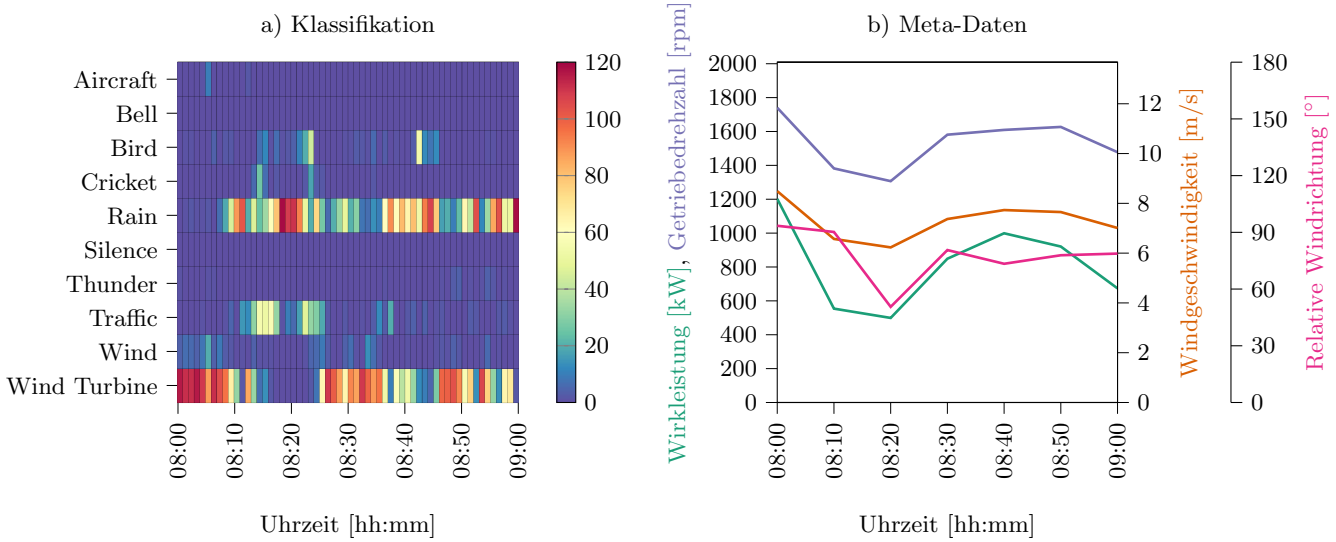

Abbildung 4: a) Klassifikation und b) Metadaten vom 21.06.2018 von 08:00 bis 09:00 Uhr. Die Farbcodierung entspricht der Anzahl an Klassifikationen der entsprechenden Klasse pro Minute (max. 120 möglich).

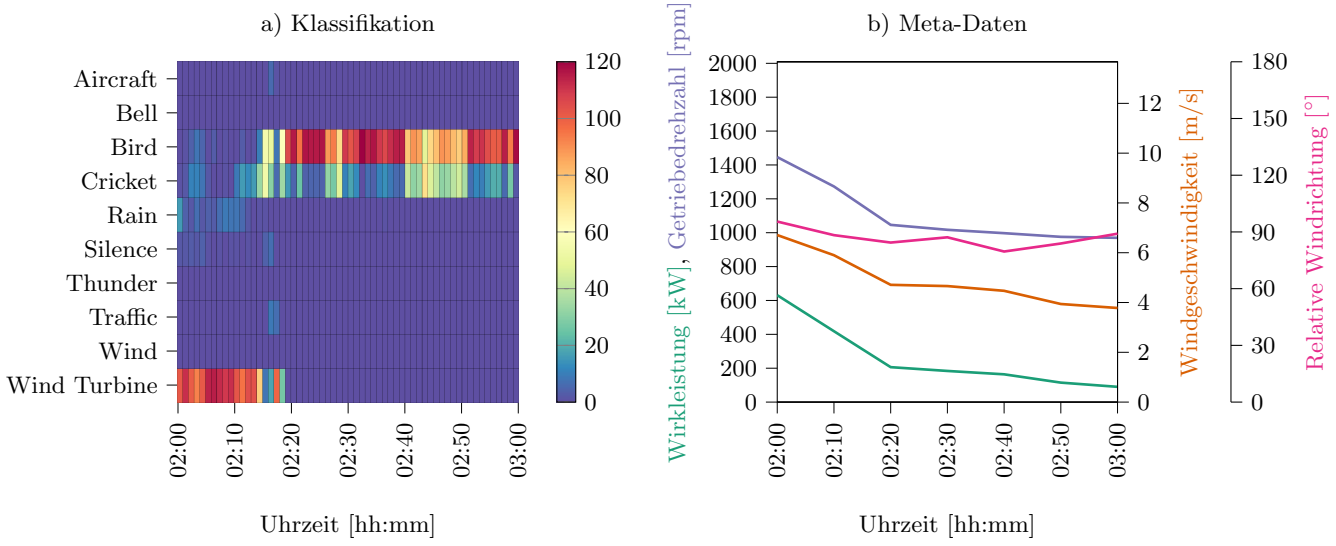

Abbildung 5: a) Klassifikation und b) Metadaten vom 25.06.2018 von 02:00 bis 03:00 Uhr. Die Farbcodierung entspricht der Anzahl an Klassifikationen der entsprechenden Klasse pro Minute (max. 120 möglich).

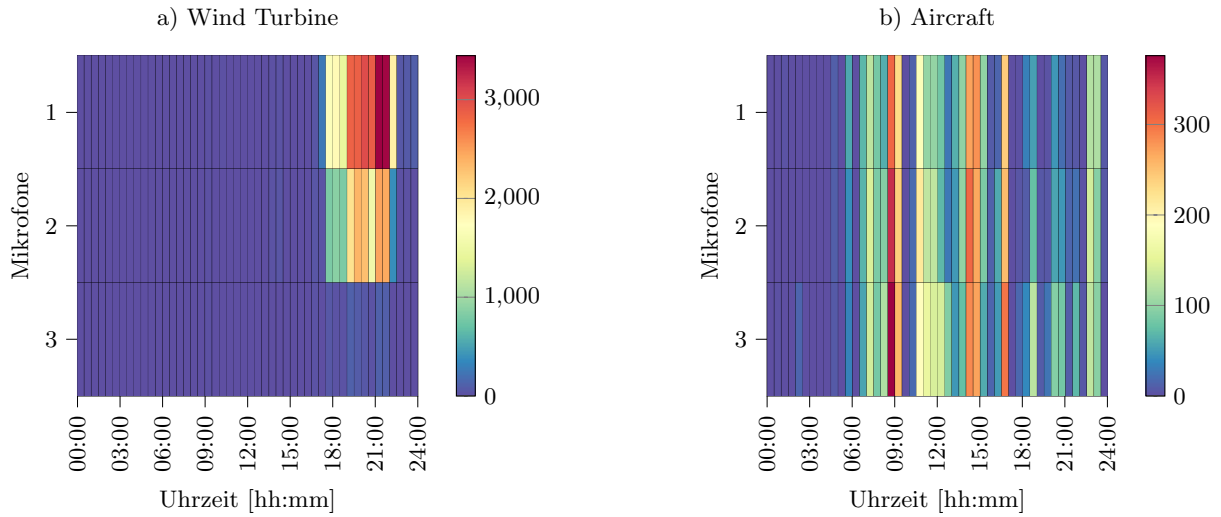

Abbildung 6: Klassifikation der Klassen a) Wind Turbine und b) Aircraft vom 09.06.2018 der drei verschiedenen Mikrofone. Die Farbcodierung entspricht der Anzahl an Klassifikationen der entsprechenden Klasse pro 30 Minuten (max. 3600 möglich).

Klasse Traffic sind nach stichprobenartiger Überprüfung als Fehlklassifikationen einzuordnen. In Zeiten hoher Getriebedrehzahl wird vermehrt die Windenergieanlage klassifiziert. Sowohl die Klassifikation des Regens als auch die Korrelation der Anzahl an Windenergieanlagen-Klassifikationen mit der Getriebedrehzahl spricht für ein in dieser Hinsicht sehr plausibles Klassifikationsergebnis.

Dieser Zusammenhang von Metadaten und Klassifikation ist auch in Abbildung 5 zu erkennen. Die in den ersten Minuten vergleichsweise hohe Drehzahl der Windenergieanlage ist durch eine große Anzahl an Klassifikationen der Klasse Windenergieanlage repräsentiert. Im weiteren Verlauf nehmen Wirkleistung und Getriebedrehzahl deutlich ab und die Windenergieanlage wird weniger bis nicht mehr erkannt. Stattdessen werden hauptsächlich Vögel und vereinzelt Grillen klassifiziert. Dieser Trend deckt sich mit stichprobenartigen, manuellen Überprüfungen durch Anhören.

In Abbildung 6 ist ein weiterer Plausibilitätstest abgebildet. Wie im Abschnitt Messaufbau erwähnt, wurden drei Mikrofone mit horizontalen Abständen von 154 m, 249 m bzw. 479 m auf einer Linie zu einer Windenergieanlage positioniert. In Abbildung 6a) sind die Klassifikationsergebnisse der Klasse Windenergieanlage und in Abbildung 6b) die Ergebnisse der Klasse Flugzeug am 09.06.2018 für die drei Mikrofone abgebildet. Dabei ist zu beachten, dass die Skalierung der Farbcodierung nicht einheitlich ist und für jede Klasse auf das jeweils auftretende Maximum normiert ist.

Je nach Klasse sind a priori unterschiedliche Konstellationen der Klassifikationsergebnisse der verschiedenen Mikrofone zu erwarten. Bei der Klasse Wind Turbine ist davon auszugehen, dass die Windenergieanlage mit steigender Entfernung weniger deutlich bzw. seltener zu hören ist und somit auch weniger oft klassifiziert werden sollte. Dieses Verhalten ist in dem abgebildeten Ergebnis deutlich zu erkennen. Es wird für die verschiedenen Mikrofone etwa zu den gleichen Zeitpunkten eine Windenergieanlage klassifiziert. Mit größer werdendem Abstand nimmt die Anzahl an Klassifikationen allerdings deutlich ab. Die nicht vorhandenen Klassifikation der Windenergieanlage außerhalb des Zeitraums von ca. 18:00 bis 21:30 Uhr stimmen zudem mit den Metadaten der Anlage überein (nicht abgebildet).

Bei der Klasse Aircraft hingegen sind keine größeren Unterschiede der Klassifikation in Abhängigkeit von der Position des Mikrofons zu erwarten. Auch dieses Verhalten spiegelt sich in den Klassifikationsergebnissen wider. Die Anzahl der Klassifikationen pro Zeiteinheit unterscheiden sich bei den verschiedenen Mikrofonen nur gering und auch die sehr geringe Anzahl an Klassifikationen in der Nacht ist plausibel.

Fazit

Die vorgestellten Ergebnisse zeigen, dass eine Machine Learning basierte Klassifizierung von Außenschallszenen mit 10 unterschiedlichen Klassen grundsätzlich möglich ist und dabei Klassifikationsraten im Bereich 59-100 % (durchnittlich 84 %) erzielt werden können. Die Plausibilitätsprüfungen haben ergeben, dass die Ergebnisse der Klassifikation mit den Informationen aus den Metadaten korrelieren. Es sind jedoch noch weitere Arbeiten notwendig, um die Güte der Klassifikation noch genauer beurteilen zu können. In der Zukunft sind eine Erweiterung des gelabelten Datensatzes sowie eine Anpassung an eine Multi-Label-Klassifikation geplant. Des Weiteren werden weitere Deep Learning Architekturen untersucht.

Förderung

Das Projekt WEA-Akzeptanz ist gefördert vom Bundesministerium für Wirtschaft und Energie (BMWi) unter dem Förderkennzeichen 0324134A.

Literatur

[1] Aurelien Géron, Hands-On Machine Learning with Scikti-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems: O'Reilly Media, 2019.

[2] Martin Abadi et al., TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. [Online]. Verfügbar: https://www.tensorflow.org/.

[3] WEA-Akzeptanz. [Online]. Verfügbar: https://www.wea-akzeptanz.uni-hannover.de/wea-akzeptanz.html.

[4] WetterKontor. [Online]. Verfügbar: https://www.wetterkontor.de.