

Methoden des Maschinellen Lernens als Hilfe bei der Fremdgeräuschkorrektur von Lärmimmissionsmessungen

Thomas Schenk¹, Konrad Schenk

¹ KSZ Ingenieurbüro GmbH, 13086 Berlin, E-Mail: tschenk@ksz-akustik.de

Einleitung

Dieser Beitrag soll am Beispiel der Fremdgeräuschkorrektur von Lärmimmissionsmessungen zeigen, wie moderne Methoden des Maschinellen Lernens auch im Bereich des Lärmschutzes eingesetzt werden können.

Bei Lärmimmissionsmessungen sind häufig Korrekturen zum Ausschluss der Wirkung von Fremdgeräuschen erforderlich. Diese Fremdgeräuschkorrektur ist bei Messdauern von einigen Minuten bis Stunden (Kurzzeitmessungen) relativ einfach möglich, indem während der Messung vor Ort Zeitpunkt bzw. –dauer des Auftretens verschiedener Geräuschquellen notiert werden und danach im Labor die Fremdgeräuschkorrektur rechnerisch vorgenommen wird. Moderne Schallpegelmesser verfügen über die Möglichkeit der Speicherung des Pegel-Zeitverlaufes im Messgerät und des Setzens von Markern. Fremdgeräusche oder anderweitig besonders zu berücksichtigende Geräusche können damit während der Messung markiert werden. Mit einer entsprechenden Auswertesoftware kann die Fremdgeräuschkorrektur nach der Messung komfortabel am PC vorgenommen werden.

Bei Messdauern von mehreren Tagen oder Wochen (Langzeitmessungen) ist eine ständige Präsenz des Messtechnikers vor Ort nicht mehr möglich. Deshalb wird versucht, die Zuordnung von (Fremd-)Geräuschquellen zu bestimmten Ereignissen im Pegel-Zeitverlauf anhand von während der Messung gespeicherten Audioaufzeichnungen (teilweise auch Videoaufzeichnungen) im Labor vorzunehmen. Dies ist sehr zeitaufwändig, fehleranfällig und für den auswertenden Messtechniker auf Dauer sehr belastend. Bei permanent arbeitenden Dauermessstationen (z.B. an Flughäfen) werden deshalb auch verschiedene automatisierte Verfahren zur Unterstützung der Quellenerkennung eingesetzt, welche jedoch derzeit auf Geräusche mit relativ einfacher Struktur beschränkt sind. Sind die zu beurteilenden Geräusche komplexerer Natur, so werden in der derzeitigen Messpraxis entweder vor dem Auftreten dieser Geräusche so genannte „Null-Messungen“ zur Grob-Abschätzung des Fremdgeräuschpegels durchgeführt oder es wird ganz auf eine Fremdgeräuschkorrektur verzichtet und das Messergebnis als „worst case“ verkauft. Jede dieser Vorgehensweisen ist sehr unbefriedigend (um nicht zu sagen unakzeptabel) und es muss nach alternativen Methoden gesucht werden.

Tiefe Neuronale Netze

Tiefe Neuronale Netze (Deep Neural Networks – DNN) haben sich in verschiedenen Bereichen zur Objekt- bzw. Mustererkennung bewährt. Es war deshalb naheliegend, die Zuordnung akustischer Quellen anhand des Audiosignals ebenfalls mittels DNN zu versuchen. Die hohen Erwartungen in die Erkennungsleistung eines solchen Netzes wurden zunächst jedoch enttäuscht. Die Gründe hierfür sind

unterschiedlicher Natur und liegen vor allem in der sehr hohen Komplexität und Vielfalt alltäglicher Geräusche begründet. Im Gegensatz zu gängigen Musik- oder Sprach-Erkennungsverfahren haben wir es hier mit nicht-regelbasierten Geräuschen zu tun, welche zudem durch gleichzeitiges Auftreten verschiedener Quellen sowie durch unterschiedliche akustische Beeinflussungen auf dem Ausbreitungsweg nahezu unbegrenzte Vielfältigkeit und Komplexität erreichen können. Weitere Schwierigkeiten beim Aufbau eines DNN zur Geräuschquellenerkennung liegen in der Auswahl einer geeigneten Netzarchitektur, geeigneter Lernverfahren sowie in der Verfügbarkeit einer ausreichenden Anzahl von Trainingsdaten.

Es war deshalb notwendig, die Geräuschquellenerkennung auf bestimmte, relativ einfach strukturierte Geräuscharten zu beschränken. Für die Fremdgeräuschkorrektur muss hierbei zwischen Positivselektion und Negativselektion unterschieden werden. Haben die zu beurteilenden Geräusche eine relativ einfache Struktur (z. B. Fluggeräusche), ist es sinnvoll zu versuchen, dass diese Geräusche auch durch das DNN erkannt werden (Positivselektion). Haben die zu beurteilenden Geräusche jedoch eine zu große Vielfalt und Komplexität (z. B. Baustellengeräusche), ist es einfacher zu versuchen, auftretende Fremdgeräusche zu erkennen (Negativselektion). Es wird davon ausgegangen, dass nach erfolgreichem Erkennen und Ausschluss aller Fremdgeräuschquellen die verbleibenden Geräusche der zu beurteilenden Quelle zugeordnet werden können bzw. dass zumindest die verbleibenden Geräusche pegelmäßig durch das zu beurteilende Geräusch bestimmt werden.

In unserer Messpraxis sind die für die Negativselektion wichtigen Geräuschquellenarten vor allem Verkehrsgeräusche (Schiene, Straße, einschließlich Martinshorn, Autohupen u. ä.), Wind- und Regengeräusche, Tiergeräusche (Hunde, Vögel), Glockengeläut und menschliche Lautäußerungen.

Methodik

Abbildung 1 verdeutlicht die Vorgehensweise bei der Installation eines DNN zur Geräuschquellenerkennung. Das DNN muss anhand von möglichst vielen bekannten, klassifizierten Audiodaten trainiert werden. Der Umfang der Trainingsdaten sollte pro Geräuschklasse mehrere hundert Beispiele umfassen. Die Daten müssen zunächst akustisch vorverarbeitet (Pegelanpassung, Bandbegrenzung) und in den Frequenzbereich transformiert werden. Im Ergebnis des Trainings liegt ein Parameterdatensatz für jede zu erkennende Geräuschklasse vor, anhand dessen das DNN später unbekannte Geräusche identifiziert und klassifiziert. Bevor das DNN jedoch in der Praxis eingesetzt werden kann, muss es mittels Testdaten verifiziert werden. Die Testdaten dürfen nicht mit den Trainingsdaten identisch sein. Die Verifizierung wird in den seltensten Fällen eine Erkennungsrate von 100% für alle

Geräuschklassen ergeben. Erkennungsraten über 80% sollten jedoch angestrebt werden.

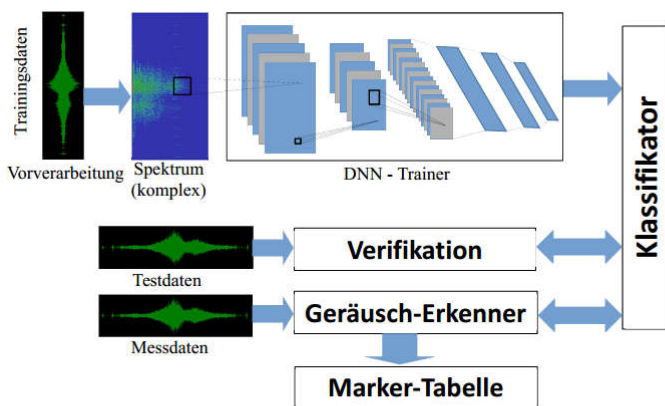


Abbildung 1: Beispiel für die Anwendung von DNN zur Geräuschquellenerkennung

Ergibt die Verifizierung akzeptable Erkennungsraten, kann das Netz in die Praxis überführt werden. Hierbei werden die bei der Messung auftretenden Geräusche in das DNN (online oder offline) eingelesen. Die Geräusche werden vom DNN analysiert und den Geräuschquellenklassen mit Angabe einer entsprechenden Wahrscheinlichkeit zugordnet. Im Ergebnis wird eine Markertabelle mit Zeitstempel für Anfang und Ende von erkannten Geräuschen sowie mit einer Angabe zur Erkennungswahrscheinlichkeit p in % erzeugt (Tabelle 1).

Tabelle 1: Beispiel einer Markertabelle

Beginn	Ende	Quelle	p
20180115-043010	20180115-043812	Vögel	75
20180115-062212	20180115-062213	Hupe	89
20180115-084145	20180115-084151	Tram	82
20180115-095213	20180115-103355	Regen	92
...
...
...
...

Die Struktur dieser Tabelle (zumindest der ersten drei Spalten) ist prinzipiell identisch mit den Markertabellen, die bei der Bearbeitung von Pegel-Zeitverläufen mit der Auswertesoftware moderner Schallpegelmesser erstellt werden. Der Unterschied liegt lediglich darin, dass statt einer automatischen Zuordnung durch das DNN bei der Bearbeitung von gespeicherten Pegel-Zeitverläufen der Messtechniker die Quellzuordnung anhand der vorliegenden Informationen (z. B. aus Tonaufzeichnungen) per Hand am Computer vornehmen muss. Es würde sehr viel Zeit bei der Auswertung von Pegel-Zeitverläufen gespart werden können, wenn als nächster logischer Schritt in die Auswertesoftware eine Import-Schnittstelle (z. B. ASCII oder Excel) für Markertabellen implementiert werden könnte.

Ergebnisse

In nachfolgender Tabelle 2 sind die Ergebnisse der Verifizierung der ersten Variante des installierten DNN als Auszug für einige Beispiele von Geräuschquellenarten aufgeführt.

Tabelle 2: Erkennungsraten
(Da es sich um einen Auszug aus der Tabelle aller Ergebnisse handelt, ergeben die Summen nicht 100%)

Erkennungsraten in %	Eisenbahn	Glocken	Regen	Hunde	Martinshorn	Autohupen	...
Eisenbahn	92,3	0,1	1,3	0,0	0,2	0,0	...
Glocken	0,0	91,7	0,0	0,0	6,8	1,1	...
Regen	0,0	0,0	73,2	0,0	0,0	0,0	...
Hunde	0,0	0,0	8,0	85,9	0,0	0,0	...
Martinshorn	0,0	0,0	0,0	0,0	55,6	44,4	...
Autohupen	0,0	0,0	0,0	0,0	0,0	100	...
...

Die Tabelle enthält in den Spalten und Zeilen die Erkennungsraten für die jeweilige Kombination von Geräuschklassen. In der Diagonalen sind die Erkennungsraten für eine korrekte Zuordnung der jeweiligen Geräuschklassen enthalten. Die anderen Felder enthalten die Erkennungsraten für die Fälle, in denen ein Geräusch einer bestimmten Geräuschklassenart fälschlicherweise einer anderen Klasse zugeordnet wurde. Wie zu erkennen ist, sind nicht für alle Geräuschklassenarten zufriedenstellende Erkennungsraten erreicht worden. Die Geräusche der Martinshörner von Feuerwehr- bzw. Polizeifahrzeugen wurde z. B. zu 44% mit Autohupen verwechselt. Eine nähere Untersuchung ergab in einer Reihe von Fällen kontaminierte Trainingsdaten als Ursache für eine mangelhafte Erkennung. Wenn beispielsweise in den Trainingsdaten für Martinshörner und Autohupen zusätzlich Motorgeräusche enthalten sind, können diese Klassen nicht immer sauber voneinander getrennt werden. Weiterhin wird vermutet, dass der Umfang der Trainingsdatensätze bzw. die Varianz der Trainingsdaten (Aufzeichnungen von verschiedenen Quellen der gleichen Geräuschklassenart) in einigen Geräuschklassen nicht ausreichend groß war. Derzeit wird mit einem verbesserten Trainingsdatensatz das Netz neu trainiert, in der Hoffnung, im Ergebnis für alle Geräuschklassen ausreichend gute Erkennungsraten zu erzielen.

Zusammenfassung

Tiefe Neuronale Netze sind eine geeignete Methode zur Identifizierung von akustischen Signalen und ihrer Zuordnung zu bestimmten Geräuschklassen bzw. Geräuschklassenarten. Mit einer geeigneten Netzarchitektur und ausreichendem Umfang an Trainingsdaten sind auch feinere Differenzierungen als hier beschrieben möglich. So konnte bereits mit einem anderen Netz eine Unterscheidung zwischen den Geräuschen von Turboprop-Flugzeugen, strahlgetriebenen Flugzeugen und Helikoptern erfolgreich realisiert werden.

Mit entsprechend gut trainierten Netzen können ausreichend gute Erkennungsraten und reproduzierbare Ergebnisse erzielt werden. Der größte Vorteil liegt in einer immensen Zeitersparnis im Vergleich zu einer manuellen Zuordnung von Audioaufzeichnungen zu bestimmten Geräuschquellenarten. Fragliche Fremdgeräuschabschätzungen mittels „Null-Messung“ können vermieden werden. Auch in den Fällen, bei denen bislang aus Aufwandsgründen auf eine Fremdgeräuschkorrektur verzichtet wurde, ist mittels der Methode der Geräuschquellenzuordnung durch DNN die Ermittlung eines ordentlichen Beurteilungspegels möglich.

Diesen Vorteilen stehen jedoch einige Nachteile gegenüber. Für Entwurf und Realisierung eines DNN sind Spezialkenntnisse in Mathematik und EDV sowie ein hoher Einarbeitungsaufwand im Bereich Deep Learning erforderlich. Die Netzarchitektur und die anzuwendende Trainingsmethode muss der jeweiligen Aufgabenstellung angepasst werden. Werden mehrere Messstellen für das gleiche Objekt betrieben, so muss ein messstellenabhängiges Training erfolgen. Hieraus ergibt sich, dass der Einsatz von DNN zur Geräuschquellenenerkennung wirtschaftlich nur bei Dauer-messstellen durchführbar ist.