

# Systemidentifikation von nicht-linearen Sekundärstrecken in active noise control Systemen mit Hilfe Neuronaler Netzwerke

Michael Wolff<sup>1</sup>, André Jakob<sup>1</sup>, Michael Möser<sup>1</sup>

<sup>1</sup> Institut für Technische Akustik, Einsteinufer 25, D-10587 Berlin, Deutschland, Email: wolff@mach.ut.tu-berlin.de

## Einleitung

Im Rahmen eines DFG-Projektes wird am ITA der TU Berlin an einer Hochleistungs-Antischallquelle für tiefe Frequenzen geforscht (siehe auch [1]). Da sich solche Quellen, die mit modulierter Luftströmung arbeiten, stark nicht-linear verhalten, ist neben der Optimierung dieser Schallquellen ein Forschungsschwerpunkt die Integration von nicht-linearen Sekundärstrecken in die Strukturen der aktiven Lärmbekämpfung. Hier wird über Ansätze berichtet, die mit künstlichen Neuronalen Netzen arbeiten. Diese sogenannten „time-delay neural networks“ lassen sich als nicht-lineare Filter verstehen. Im Folgenden werden Verfahren zur Systemidentifikation der vorliegenden nicht-linearen Sekundärstrecke mit Neuronalen Netzwerken vorgestellt und Simulationsergebnisse aufgezeigt.

## Motivation

Die aktive Regelungskette soll als feedforward Regler nach der bekannten *filtered-x* Methode implementiert werden. Da die vorhandene physikalische Sekundärstrecke stark nicht-lineares Verhalten aufweist (vergl. [1]), sollen sowohl die Schätzung der Sekundärstrecke, als auch der Controller selbst, dem die Aufgabe der Erzeugung des zur Auslöschung benötigten Sekundärsignals zukommt, als nicht-lineare Filter ausgeführt werden.

## Systemidentifikation

Im Gegensatz zu den linearen Systemen, bei denen das System durch Messung von Übertragungsfunktion und/oder der Impulsantwort eindeutig beschrieben werden kann, gibt es bei nicht-linearen Systemen keine vergleichbare Technik. Nicht-lineare Systeme besitzen eine Vielzahl von Impulsantworten und weisen ein frequenz- und amplitudenabhängiges Übertragungsverhalten auf.

Eine Modellbildung für den nicht-linearen Fall kann z.B. mit künstlichen Neuronalen Netzen erfolgen. Hierbei wird das zu modellierende System als 'Black Box' verstanden und die Übertragungseigenschaften durch Kenntnis von Ein- und Ausgangssignal ermittelt. Wie im linearen Fall lassen sich unterschiedliche generelle Modellstrukturen definieren, wie z.B. FIR, ARX, ARMAX, OE, BJ, etc.([3]).

## Neuronale Netze

Neuronale Netze (NN) sind informationsverarbeitende Systeme, die aus einer großen Anzahl von miteinander verbundenen, einfachen Einheiten (Neuronen) aufgebaut sind. Die Stärke der Verbindungen der einzelnen Neuronen untereinander wird dabei mit bestimmten Algorithmen so angepasst, dass ein durch das Netzwerk verarbeitetes Signal in

gewünschter Weise verzerrt wird. Damit gleicht die Signalverarbeitung durch ein NN der eines bekannten digitalen Filters, jedoch mit der Möglichkeit sowohl lineare als auch nicht-lineare Funktionen zu realisieren. Diese Eigenschaft des NN wird durch die sog. *Aktivierungsfunktion* (AF) ( $f_h$  in Abb. 1) jedes einzelnen Neurons gewährleistet. Die AF's werden in der Regel als *tanh-Funktion* ausgeführt.

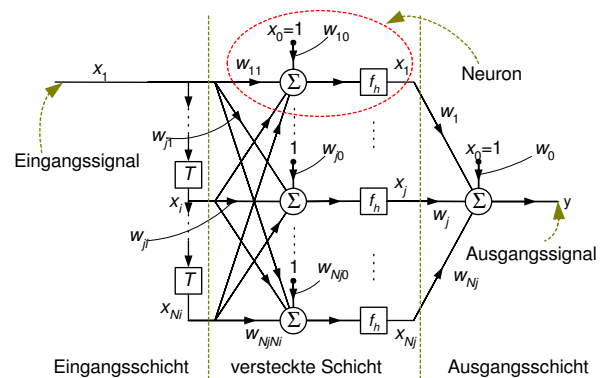


Abbildung 1: Time Delay Neural Network

In Abb. 1 ist ein sog. (nicht-rekursives) *Time Delay Neural Network* dargestellt. Das Eingangssignal liegt mit einer gewissen Anzahl verzögerter Samples an der Eingangsschicht des NN an. Die einzelnen Neuronen bilden eine oder mehrere versteckte Schichten und verarbeiten sämtliche parallel anliegende Samples ( $x_i$ ), indem diese gewichtet ( $w_{ji}$ ), summiert und mit der AF ( $f_h$ ) bewertet werden. Einen zusätzlichen Eingang bildet der sog. Biastharm ( $w_{j0}$ ), der dafür zuständig ist, den Arbeitspunkt des Neurons einzustellen.

Das Neuron formuliert sich damit mathematisch zu:

$$x_j = f_h \left( \sum_{i=1}^{N_i} w_{ji} x_i + w_{j0} \right) \quad (1)$$

Die Ausgangsschicht besteht aus einem oder mehreren Neuronen mit linearer AF. Diese hat damit die Aufgabe, die Signale der einzelnen Neuronen zu summieren und zu skalieren, so dass alle Amplituden ermöglicht werden.

## Modellbildung

### Modellstruktur

Um mit Hilfe der NN das oben genannte System zu identifizieren, wurde eine nicht-lineare ARX Modellstruktur gewählt. Die *Eingangsdelayline* des NN besteht hierbei aus gemessenen Ein- und Ausgangssignalen.

### Eingangssignal

An das zur Identifikation verwendete Eingangssignal werden z.B. die Anforderungen gestellt, sämtliche Kombinationen aus interessierenden Frequenzen und Amplituden zu enthalten. Besonders geeignet für nicht-lineare Systeme ist das *Random Walk* Signal, das aus Sprüngen auf unterschiedliche Amplituden besteht, wobei die Länge der Sprünge ebenfalls variiert und mind. die Länge des Systemdelays haben sollte.

### Training und Validierung

Das Netzwerk wird mit einem Gradientenverfahren 2. Ordnung dem sog. Levenberg-Marquard Algorithmus [2] trainiert. Im Netzwerk selbst sind die richtigen Dimensionen im Hinblick auf die Anzahl der Eingangsdelays und die Anzahl Neuronen zu wählen. Ein hierbei häufig auftretendes Problem ist das sog. *overfitting*: zu viele Neuronen bilden zunehmend das Rauschen des Trainingssignals nach. Für unbekannte Signale (*Validierungssignale*) steigt der Fehler des geschätzten Signals ab einer bestimmten Anzahl von Neuronen dann wieder an, obwohl der Trainingsfehler weiterhin sinkt. Gleiches gilt für die Anzahl der Eingangsdelays. In Abb. 2 ist der Zeit-




Abbildung 2: Trainingssignal (l) und Validierungssignal (r)

und Frequenzbereich für ein übertrainiertes Netzwerk dargestellt. Verglichen wird hier der vom Netzwerk simulierte Ausgang mit dem gemessenen Ausgang für das Trainingssignal (links) und das Validierungssignal (rechts).

Mit Akaikes Prediction Error wurde für verschieden große Netzwerke mit unterschiedlich vielen Eingangsdelays ein Kriterium gewählt, mit Hilfe dessen sich verschiedene Strukturen miteinander vergleichen lassen. In Abb. 3 ist links der Validie-




Abbildung 3: Validierungs- und Trainingsfehler

rungsfehler für zwei Validierungssignale aufgetragen; deutlich zu erkennen ist ein Minimum für ca. 15 Neuronen und ebenfalls 15 Eingangsdelays. Das Netzwerk wurde deshalb mit diesen Werten dimensioniert. Für den Trainingsfehler in Abb. 3 ist deutlich der zu erwartende Abfall mit größer werdender Netzwerkdimension zu erkennen.

### Validierung mit Sinusfunktionen

Bei der untersuchten Anwendung zeigte sich, das aufgrund des besonders hohen Rauschanteils der Schallquelle eine Validierung mit rauschartigen Signalen nicht sinnvoll erscheint. Es wurden daher auch Sinusanregungen zur Validierung verwendet, da die Schallquelle für solche Signale gedacht ist.




Abbildung 4: Validierung mit 40 Hz und 60 Hz

In Abb. 4 sind zwei Beispiele dargestellt. Für den 40 Hz Ton stimmt die Grundwelle in Betrag und Phase gut überein. Die harmonischen Oberwellen werden zwar alle erzeugt aber mit zu geringer Amplitude. Ein ähnliches Verhalten zeigt sich für den 60 Hz Ton, wobei die Phase der Grundwelle zu höheren Frequenzen hin schlechter geschätzt wird.

### Zusammenfassung und Ausblick

Gezeigt wurden Ansätze zur Modellbildung von nicht-linearen Sekundärstrecken mit Hilfe Neuronaler Netzwerke. Dabei wurden die wesentlichen Prinzipien und die zu wählenden Parameter angesprochen, wie z.B. die Auswahl der Modellstruktur, das Eingangssignal, die Anzahl der Neuronen sowie die Anzahl der Eingangsdelays. Bei der gewählten Anwendung ist die Problematik des *overfitting* von entscheidender Bedeutung.

Eine Auswertung der Modelle zeigte, dass die Grundwellen der Signale gut geschätzt werden, die Oberwellen zwar erzeugt aber unterschätzt werden.

In weiteren Arbeitsschritten sollen zum Einen Trainingssignale verwendet werden, die der angestrebten Anwendung besser entsprechen, wie z.B. Gleitsinussignale veränderlicher Amplitude. Zum Anderen soll die Eignung anderer Modellstrukturen, wie z.B. OE, ARMAX, untersucht werden.

### Literatur

- [1] Weiß, D., Wolff, M., Jakob, A., Möser, M. (2005). Modellbildung und Untersuchungen an einer elektropneumatischen Schallquelle zur Verwendung als Antischallquelle. DAGA - Fortschritte der Akustik 05.
- [2] Norgaard, M., Ravn, O., Poulsen, N.K., Hansen, L.K. (2000). Neural Networks for Modelling and Control of Dynamic Systems. Springer Verlag London Limited.
- [3] Ljung, L., Glad, T. (1994). Modeling of Dynamic Systems. PTR Prentice Hall.