




Hochschule
Kaiserslautern
University of
Applied Sciences

Angewandte
Ingenieurwissenschaften
Kaiserslautern

P3E Power Electronics,
Electronics and EMC




Prof. Dr.-Ing. C. Schumann


KI-basierte Ansteuerung von leistungselektronischen Schaltungen als Laborpraktikum

Jennifer Piela, B. Eng., Prof. Dr.-Ing. C. Schumann


03.06.2025



Unsere Multiversuchshardware





- Vorangehendes SQL-Projekt
- Selbst entworfenes Design
- Einzigartige Hardware
- Modulare Auslegung



Multiversuchshardware im Labor


- Einsatz im
Leistungselektronik-Labor
- Vier Versuche – eine
Hardware
- Gutes Feedback von
Studierenden






Klassische Regelanwendung :


- Geeignet für bekannte Systeme
- Für einen Arbeitspunkt optimal
- Schnelle Reaktionszeit






Klassische Regelanwendung :


- Suboptimal für neue Systeme
- Neue Auslegung notwendig






KI Regelanwendung :


- Selbstlernendes Steuerverfahren
- Optimale Regelung für jeden Arbeitspunkt
- verbesserungsfähig





Voraussetzungen an Studierende:

- Grundkenntnisse zu KI
- Grundkenntnisse in der Programmierung
- Grundkenntnisse von leistungselektronischen Schaltungen



Wiederholung von KI-Grundkenntnissen:

- Begriffserklärung
- Eigenrecherche zu KI-Lerntypen
- Schritt-für-Schritt-Anleitung:
 - Einfache NN trainieren
 - Einfluss der Trainingsdaten auf Lernprozess
 - Einfluss von Trainingsparameter

Labor Leistungselektronik

Neuronale Netze (NN)

Neuronale Netze sind das Kernstück von vielen KI-Verfahren, denn sie ermöglichen es, aus den Eingabedaten passende Ausgabedaten zu erzeugen. Dies geschieht durch das Anpassen und Optimieren der Gewichte und Bias, bis das gewünschte Verhalten erreicht wird.

Dazu werden Geflechte aus mathematischen Funktionen eingesetzt, die als Neuron bezeichnet werden. Ein Neuron besteht aus Gewichten w_i und einem Bias b . Sie folgen dem Aufbau:

$$y = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b = \left(\sum w_i \cdot x_i \right) + b$$

Ein Neuron besitzt genauso viele Gewichte wie es Eingänge besitzt und die Anzahl der Eingänge hängt vom Aufbau der Neuronenstruktur ab.

Ein NN besteht nun aus mehreren Neuronen, die in Schichten angelegt werden. Innerhalb einer Schicht verlaufen die Berechnungen der Neuronen parallel.




Abbildung 1: Schematische Darstellung eines NN.

Die gezeigte Darstellung in Abbildung 1 zeigt den Aufbau eines einfachen neuronalen Netzes. Alle Ausgänge der vorangehenden Schicht werden als Eingänge in die nächste Schicht genutzt. Die erste Schicht (grün) wird als Eingangsschicht bezeichnet und umfasst die Menge an Eingangsvariablen, die definiert sind. Die dazwischenliegenden Schichten (blau) werden als versteckte Schichten, hidden layers, bezeichnet und sind nicht direkt einsehbar. Die Anzahl an Schichten und Neuronen innerhalb einer Schicht kann beliebig variiert werden. Die letzte Schicht, die Ausgangsschicht, besitzt so viele Ausgänge, wie definiert sind.

Typischerweise kommt noch eine Aktivierungsfunktion zwischen den Schichten hinzu. Diese hat den Vorteil, dass damit nichtlineare Verhaltensweisen abgebildet werden können. Beispielsweise kann eine Aktivierungsfunktion erst den Eingabewert weiterverarbeiten, wenn ein bestimmter Schwellenwert erreicht wird, ansonsten ist der Ausgabewert null.

LEL_Versuch_3_V1_1_25

Labor Leistungselektronik

Training mit Matlab

Supervised Learning als Regressionsbeispiel

An diesem Beispiel wird Ihnen gezeigt, wie man eine in Matlab ein einfaches NN auf einen Sinus trainieren kann. Hierzu werden Sie die Toolbox „Deep Learning Toolbox“ aus Matlab benötigen. Diese sollten Sie unter Add-Ons finden und installieren können, falls Sie es noch nicht haben.

Grundsätzlich kann man den Entwicklungsprozess in folgende Schritte aufteilen:

1. Trainingsdaten vorbereiten
 - a. In unserem Beispiel wird es eine Periode von einem Sinus sein
2. NN aufbauen
 - a. Für unser Beispiel wird ein Input und ein Output benötigt
3. Trainingsoptionen definieren
 - a. Festlegen der Anzahl der Iterationen und der Lernraten
4. Trainingsprozess
 - a. Das Durchführen des Trainings basieren auf den vorhandenen Daten
5. Überprüfen des Verhaltens des NN
 - a. Mittels Testdaten kann das Verhalten getestet werden

Der Programmcode wird nun nach den obigen Schritten aufgebaut.

Trainingsdaten Vorbereiten:

Es soll ein Sinus approximiert werden. Das NN soll für gegebene x-Werte den korrekten y-Wert ausgeben können. Dafür wird ein Datensatz (x,y) benötigt, der eine Periode eines Sinus darstellt. Erzeugen Sie einen Datensatz x und y für $y = \sin(x)$.

In der Regel wird aus dem vorhandenen Datensatz sowohl die Trainingsdaten als auch die Testdaten erzeugt. Dies hat den Vorteil, dass die Ergebnisse der Testdaten mit den Originaldaten vergleichbar sind. Die 80/20-Regel hat sich hier gut bewährt. Also werden 80% der Daten für das Training benutzt und 20% für das Verifizieren am Ende. Nun erzeugen Sie einen Datensatz aus x und y, die 80% zufällig ausgewählte Daten aus dem Originaldatensatz beinhalten. Erzeugen Sie einen zweiten Datensatz, der die restlichen 20% enthält.

```
idx = randperm(SampleAnzahl) % mit dieser Funktion wird eine zufällige Anordnung von % Zahlen zwischen 0 und SampleAnzahl erzeugt
```


NN aufbauen:

Um ein NN aufzubauen, muss die Reihenfolge und Art der Schichten definiert werden. Von Matlab gibt es schon verschiedene Typen an Schichten, jedoch beschränken wir uns auf die folgenden einfachen Schichten:

Name	Schichtart	Input	Erklärung
featureInputLayer()	Eingangsschicht	Anzahl der Eingänge, Optionen	Legt die Anzahl eindimensionaler Inputs fest
fullyConnectedLayer()	Versteckte Schicht / Ausgangsschicht	Anzahl der Neuronen	Eine Schicht aus parallel angeordneten Neuronen, jedes Neuron verbunden mit allen


LEL_Versuch_3_V1_1_25

Seite 6 von 15




Visualisierung durch MatLab möglich:

- Netzstruktur mit Parametern
einsehbar
- Trainingsablauf verfolgbar
- In wenigen Sekunden bis Minuten
trainiert




Welche Arten an KI gibt es?



Supervised Learning

- überwachtes Lernen



Unsupervised Learning


- unbeaufsichtigtes Lernen



Reinforcement Learning

- verstärktes Lernen

Wie funktioniert Supervised Learning?



Training:


- Eingabedaten (Features) und passende Ausgaben (Labels)
- lernt Zusammenhänge zwischen Eingabe und Ausgabe

Ziel:

- Vorhersage Ausgabe von unbekannten Daten

Anwendung:

- Einsatz für Klassifikations- oder Regressionsaufgaben



Supervised Learning

- überwachtes Lernen


Unsupervised Learning

- unbeaufsichtigtes Lernen

Reinforcement Learning

- verstärktes Lernen

Wie funktioniert Unsupervised Learning?



Training:


- nur die Eingabedaten, keine Zielwerte

Ziel:

- Mustererkennung
- Gruppieren oder Clustern ähnlicher Daten

Anwendungen:

- Gruppierung, Anomalieerkennung



Supervised Learning

- überwachtes Lernen


Unsupervised Learning

- unbeaufsichtigtes Lernen

Reinforcement Learning

- verstärktes Lernen

Wie funktioniert Reinforcement Learning?



Training:


- Lernverfahren durch Ausprobieren von Aktionen in Umgebung
- Feedback in Form von Belohnung oder Strafe (Reward/Penalty)

Ziel:

- Strategie (Policy) entwickeln für langfristig maximale Belohnung

Anwendung:

- Optimierungsprobleme, z.B.: komplexer Steuerung, Kartenspielen



Supervised Learning


- überwachtes Lernen

Unsupervised Learning

- unbeaufsichtigtes Lernen


Reinforcement Learning


- verstärktes Lernen



Simple Anwendung zu Einstieg:

- Reduzieren der Komplexität








Steuerung im Microcontroller

Simple Anwendung zu Einstieg:


- Reduzieren der Komplexität
- Training in
Simulationsoftware
- Einfache Steuerung
entwerfen






Supervised Learning

- Trainierte KI-Steuerung auf Microcontroller
- Operationsgrenzen vom trainiertem NN kennenlernen





Unsupervised Learning

- Neue Anwendungsfälle kennenlernen: Mustererkennung
- KI soll unterschiedliche Verläufe erkennen



Reinforcement Learning


- Komplexere Lernmethoden kennenlernen
- Optimale Regelung in allen Fällen



- Trainierte KI-Steuerung auf Microcontroller
- Operationsgrenzen vom trainiertem NN kennenlernen


Steuerung der Vollbrücke:

- Lineares Verhalten
- Arbeitsbereich
 - $U_{in} = 10 - 25 \text{ V}$
 - $I_{Soll} = -2,5 - 2,5 \text{ A}$
 - $R = 10 \text{ } \Omega$
- Testen unterschiedlich gut trainierter KI-Steuerungen
- Verhalten innerhalb und außerhalb des Arbeitsbereichs
- Verändern der Last



P3E Power Electronics,
Electronics and EMC




**Hochschule
Kaiserslautern**
University of
Applied Sciences



- Neue Anwendungsfälle kennenlernen: Mustererkennung
- KI soll unterschiedliche Verläufe erkennen



KI als Regelung




Reinforcement Learning



- Komplexere Lernmethoden kennenlernen
- Optimale Regelung in allen Fällen

Was lernen die Studierenden?



Studierende lernen, ...




... wie KI-Lernprozesse aufgebaut werden



... welche KI-Typen gibt es



... wie erstellt man einfache NN



... wie man eine KI trainiert und worauf zu achten ist:




- z.B.: Normalisierung und Verteilung der Trainingsdaten



... wie sehen Verwendungsmöglichkeiten aus:

- z.B. komplexe Verhalten nachahmen, Datenanalyse automatisieren






Jennifer Piela, B. Eng.
Power Electronics, Electronics
and EMC (P3E)

Schoenstr. 11
67659 Kaiserslautern


+49 631 3724 2464

jennifer.piela@hs-kl.de

<http://www.hs-kl.de/p3e>



P3E Power Electronics, Electronics and EMC



Prof. Dr.-Ing. C. Schumann