



## Kurzfassung

Im Rahmen dieser Arbeit wird ein einfaches künstliches neuronales Netz konstruiert, welches den Standort von Türmen und Masten nur anhand von Bild- und Metadaten korrekt vorhersagen kann. Neuronale Netze stellen mathematische Modelle zur Beschreibung der Prozesse im menschlichen Gehirn dar und können für das Lösen von Aufgaben im Bereich der Objekterkennung und -klassifizierung trainiert werden. Hierfür wird zunächst ein Datensatz erstellt, der aus vielen verschiedenen Bilddaten mit je einer Angabe zur Fertigstellung des Gebäudes als Metadateninformation sowie je einer Standortklasse besteht. Diese Klassen verkörpern Regionen, in die die Bauwerke anhand ihres Standorts einsortiert werden. Danach wird mit dem Programm Tensorflow das neuronale Netz erzeugt und mit dem Datensatz gefüttert. In einem iterativen Prozess wird das Netzwerk darauf trainiert, die Standorte der einzelnen Türme und Masten richtig zu prognostizieren.

## Variationen der Aufgabenstellung

Es werden drei Varianten des Klassifikationsproblems untersucht, bei denen der Umfang des Modellinputs und der Standortklassen als Output schrittweise erhöht wird:

- **Basic Model** – Input nur Bilddaten, 3 Standortklassen
- **Advanced Model** – Input nur Bilddaten, 8 Standortklassen
- **Metadata Model** – Input Bild- / Metadaten, 8 Standortklassen

## Erstellung des Datensatzes


Die Bild- und Metadaten werden aus der Onlinedatenbank structurae.net gewonnen und direkt aus dem HTML-Code der Website extrahiert. Anschließend wird ein Datensatz, bestehend aus 1712 Elementen, gebildet, bei dem jeder Bilddatei die Angabe zum Fertigstellungszeitpunkt des Bauwerks sowie die vom Netzwerk zu ermittelnde Standortklasse zugeordnet wird.

## Trainieren des neuronalen Netzes

Für das Training des neuronalen Netzes wird der Datensatz in eine Trainingsmenge und eine Validierungsmenge (10% des Datensatzes) unterteilt. Es handelt sich um ein iteratives Verfahren, bei dem ein Schritt zunächst in der Klassifizierung der Trainingsdaten und danach in der Beurteilung der Validierungsdaten besteht. Hierbei wird der Anteil der richtigen Vorhersagen (Genauigkeit) und die einheitenlose Fehlerfunktion untersucht. Letztere stellt eine Veranschaulichung des fortschreitenden Lernprozesses des Netzwerks dar. Die Genauigkeiten sollten kontinuierlich zunehmen und die Fehlerwerte sich fortwährend verringern. Kann die Genauigkeit bei den Validierungsdaten nicht mehr weiter gesteigert werden, führt dies zum automatischen Ende des Trainingsalgorithmus.

## Übersicht der erzielten Ergebnisse

Die beiden Diagramme zeigen die Zunahme der Genauigkeit bei den Vorhersagen sowie die Verringerung der Fehlerfunktion beim iterativen Trainingsprozess am Beispiel des Advanced Model. Anschließend soll das trainierte Netzwerk eine kleine Auswahl an Testdaten klassifizieren, um den Erfolg des Trainings zu kontrollieren. Die erhaltenen Ergebnisse aus der Trainings- und Testphase aller drei Modellvarianten sind in der darunterliegenden Tabelle zusammengefasst.



	Basic Model	Advanced Model	Metadata Model
<b>Modellinput</b>	Nur Bilddaten	Nur Bilddaten	Bild- / Metadaten
<b>Modelloutput</b>	3 Standortklassen	8 Standortklassen	8 Standortklassen
<b>Anzahl Knotengewichte</b>	14,5 Millionen	29,2 Millionen	58,1 Millionen
<b>Trainingsdauer</b>	20 Epochen	22 Epochen	30 Epochen
<b>Genauigkeit Training</b>	87 %	87 %	73 %
<b>Restfehler Training</b>	17 %	20 %	11 %
<b>Genauigkeit Testphase</b>	91 %	86 %	74 %
<b>Testelemente falsch</b>	15/171	24/171	44/171

## Kooperationspartner

str.ucture ist ein Ingenieurunternehmen für Leichtbauprojekte mit Sitz in Stuttgart, das sich mit der Tragwerksplanung, der digitalen und parametrischen Planung sowie dem Wind Engineering auseinandersetzt.