



PREDICTIVE MAINTENANCE – VORHERSAGE DES FAHRBAHNZUSTANDES DER A70

PROJEKTZIEL

Für einen Straßenbaulasträger ist es unerlässlich, Maßnahmen zur Erhaltung der Infrastruktur anhand des jeweiligen Fahrbahn- und Bauwerkszustandes sowie deren Entwicklung zu planen. Genaue Vorhersageresultate können zu einer Hilfestellung bei der Kosteneffizienz der Erhaltung sein. Zum anderen kann der Gesamtentwicklung der öffentlichen Infrastruktur besser überwacht werden.

Ziel des Projektes war es, eine Lösung mit künstlicher Intelligenz zu entwickeln, welche den Zustand der Fahrbahnen mit Hilfe eines neuronalen Netzes auf 4 verschiedenen Variablen vorherzusagen: Allgemeine Unebenheiten, Längstebenheitswirkindex, Griffigkeit bei einer Messgeschwindigkeit 80 km/h und das Schadensniveau der Fahrbahn durch Rissbildung. Durch die Vorhersage wird die Bayerischen Staatsbauverwaltung in Zukunft bei der Erhaltungsplanung unterstützt.


BEREITGESTELLTE DATEN

Das Bayerische Staatsministerium für Wohnen, Bauen und Verkehr hatte die Fahrbahnzustandsdaten der A70 (Schweinfurt, Bamberg, Bayreuth) aus den Jahren 2009, 2013 und 2017 zur Verfügung gestellt. Diese Daten enthielten 4839 Fahrbahnabschnitte (100 m Länge pro Abschnitt) mit 1 – 3 Fahrspuren je Fahrtrichtung. Jeder Fahrbahnabschnitt verfügte über 134 verschiedene Merkmale, die den Fahrbahnzustand beschrieben und geografische Daten enthielten.

Zusätzlich wurden die Verkehrsdichtedaten der A70 aus den Jahren 2005, 2010 und 2015 zur Verfügung gestellt. Diese Daten enthielten den Gesamtverkehr und die durchschnittliche Anzahl des täglichen Schwer- und Leichtverkehrs.

HERAUSFORDERUNGEN

Die gelieferten Daten wurden zu drei verschiedenen Zeitpunkten erfasst, woraus sich in der Zusammenführung ein erheblicher Anteil an fehlenden Werten ergab. Aus diesem Grunde ist vor der eigentlichen Modellierung eine geeignete Imputationsmethode anzuwenden. Bei der Erstellung der Imputationsmethode war es wichtig die Korrelation zwischen den Messungen und den geografischen Daten mit einfließen zu lassen. Bei traditionellen neuronalen Netzen wird die Korrelation nicht berücksichtigt, daher wurden zusätzlich zeitabhängige multivariate neuronale Netze getestet und letztendlich ausgewählt.






ANGEWANDTE METHODEN

DATA WRANGLING

Zunächst wurden die Verkehrsdichtedaten mit den Fahrbahnzustandsdaten zusammengeführt. Danach wurden die Variablen, welche zu viele fehlende Werte (> 50%) hatten, von der nachgelagerten Modellierung ausgeschlossen.

Die Anforderung von neuronalen Netzen sieht eine Imputation der fehlenden Werte vor der Modellierung vor. Mit der Weighted Neighborhood Imputation konnten die Lücken in den Daten durch die geografischen Informationen geschlossen werden.




Weighted Neighborhood Imputation

ZEITABHÄNGIGE MODELLIERUNG NEURONALER NETZE

Wir verglichen die Vorhersageleistung von vier Modellen: Ein allgemeines neuronales Netz (ohne Zeitinformationen, NN), LSTM (Long-Short-Term-Memory), CNN (Convolutional Neural Network) und dem kombinierten Modell aus LSTM + CNN.

Zur Beurteilung der Modelle wurde R^2 verwendet. Je höher der R^2 Wert, desto besser ist das Modell. Das neuronale Netz diente als Basis und die Auswertung zeigt eine deutlich bessere Leistung der anderen Modelle. Das kombinierte Modell aus LSTM + CNN hat insgesamt die besten Vorhersageergebnisse geliefert.



Model Performance

PROJEKTERGEBNIS

Das kombinierte Modell aus LSTM + CNN wurde erfolgreich zur Vorhersage des Fahrbahnzustandes eingesetzt. Mit einer Vorhersagegenauigkeit von 60% bei R^2 zeigt sich, dass das Modell strukturiert arbeitet und zur Vorhersage genutzt werden kann

