



INTELLIGENTE PARKPLATZ- SUCHE MIT MACHINE LEARNING

KONZEPT FÜR DIE VERRINGERUNG DES INNERSTÄDTISCHEN PARKSUCHVERKEHRS

**Fraunhofer-Institut für
Intelligente Analyse- und
Informationssysteme IAIS**

Schloss Birlinghoven
53757 Sankt Augustin

Ansprechpartner
Dr. Alexander Kister
Telefon +49 2241 14-3156
alexander.kister@iais.fraunhofer.de

www.iais.fraunhofer.de

Jede Autofahrt endet mit der Suche nach einem Parkplatz. Besonders in Innenstadtbereichen ist die Parkplatzzuche sehr zeitaufwändig und je länger die Parkplatzzuche dauert, desto schädlicher wird es auch für die Umwelt. Barbara Lenz, Leiterin des Instituts für Verkehrsforschung am Deutschen Zentrum für Luft- und Raumfahrt (DLR), schätzt die Dimension des Problems in einem Tagesschau-Interview wie folgt ein: »In Spitzenzeiten beträgt der Parksuchverkehr in den Innenstädten bis zu einem Drittel des eigentlichen Verkehrs, also ein Drittel der Autofahrer fahren nur herum, weil sie einen Parkplatz suchen.«¹ In dem vom Bundesministerium für Wirtschaft und Energie (BMWi) geförderten Forschungsprojekt GEISER wurde unter anderem ein Prototyp für einen intelligenten Parkassistenten entwickelt, der dieses Problem lösen könnte.

In dem Projekt haben Wissenschaftlerinnen und Wissenschaftler des Fraunhofer IAIS zusammen mit Partnern daran gearbeitet, Geo- und Sensordaten für Anwendungen des Alltags besser nutzbar zu machen. Dabei wurde in Kooperation mit dem Unternehmen TomTom ein Prototyp für einen intelligenten Parkassistenten entwickelt, der vorhersagen kann, wo und mit welcher Wahrscheinlichkeit ein freier Parkplatz zu finden sein wird. Der Assistent kann perspektivisch in Navigationsgeräte integriert werden und benötigt im Gegensatz zu anderen Lösungen keine zusätzliche Hardware. Dank Verfahren des maschinellen Lernens lernt der Assistent kontinuierlich hinzu und wird, auch wenn anfangs nur wenige Daten vorliegen, mit der Zeit immer zuverlässiger.

Erste Ideen und Ansätze dazu gibt es schon länger: Eine Herangehensweise wäre beispielsweise die Installation von Sensoren, die messen, ob ein Parkplatz belegt oder frei ist. So könnten Autofahrer abfragen, wo sie parken können und gezielt zu einem freien Parkplatz in der Nähe ihres Ziels navigieren. Der Aufbau und die Instandhaltung eines solchen flächendeckenden Parkplatzsensoren-Netzwerkes wäre aber mit einem hohen Zeit- und Kostenaufwand verbunden. Die Frage ist also: Wie lässt sich die Parkplatzsuche auch ohne Sensoren effizient gestalten?

In der Publikation »Prediction Machines«² wird Vorhersage knapp als das Auffüllen von Wissenslücken definiert. Eine Vorhersage beruht also immer auf bestehendem Wissen, das verwendet wird, um noch nicht gemachte Beobachtungen vorherzusagen. Das bereits bestehende Wissen liegt in der Regel schon als Datensatz vor.

»Dieser Parkplatz ist zu 96 Prozent frei!«

Ortsansässige Fahrer finden in der Regel schneller einen Parkplatz als ortsfremde Fahrer. Das zeigt, dass die Beobachtung der üblichen Parksituation in einer bestimmten Region hilfreich für die Parkplatzsuche ist. Dieses Erfahrungswissen soll genutzt werden. Ziel ist es, ein Computersystem zu entwickeln, das in der Lage ist, Vorhersagen darüber zu treffen,

ob in einem Straßenabschnitt ein Parkplatz frei sein wird oder nicht. Vorhersagen treffen mit Hilfe eines Computers ist die wesentliche Aufgabe des maschinellen Lernens, weshalb auch der GEISER-Prototyp diese Technologie nutzt.

Die initiale Schätzung als Anfangspunkt

Welche Beobachtungen über die Parkplatzbelegung lassen sich als Grundlage für das maschinelle Lernsystem verwenden? Auf den ersten Blick scheinen die Fahrwege der Nutzerinnen und Nutzer von Navigationssystemen als eine gute Quelle. In der Praxis zeigt sich aber, dass das Navigationssystem häufig vor Erreichen des Parkplatzes ausgeschaltet wird. Wesentlicher Grund dafür ist die wiederholt freundliche Aufforderung

Matt Taddy, Vice President of Economic Technology and Chief Economist for North America bei Amazon, beschreibt die Fähigkeit, kontinuierlich Daten zu erzeugen und von diesen zu lernen, als eine wesentliche Eigenschaft von KI-Systemen: »Beyond ML and domain structure, the third pillar of AI is data generation. I'm using the term 'generation' here, instead of a more passive term like 'collection', to highlight that AI systems require an active strategy to keep a steady stream of new and useful information flowing into the composite learning algorithms«³

des Systems, man möge bitte umkehren (»Bitte wenden«) – das System erkennt nämlich nicht, dass der Fahrer auf Parkplatzsuche ist. Der im Forschungsprojekt entwickelte Ansatz basiert daher auf der Überlegung, mit Hilfe einer initialen Schätzung einen ersten Parkassistenten zu erstellen, der seine Vorhersagequalitäten im Laufe der Nutzung immer weiter verbessern wird. Die Aufgaben des Parkassistenten sollen sein:

1. Den Nutzer in kürzester Zeit so nah wie möglich an sein Ziel bringen
2. Ständig bessere Schätzungen der Parkwahrscheinlichkeiten lernen

Zwischen diesen Zielen besteht jedoch ein Konflikt: Um Ziel 2 zu erreichen, könnte der Assistent einen Autofahrer gezielt in den Straßen suchen lassen für die noch wenig Beobachtungen vorliegen – selbst dann, wenn der Algorithmus sich relativ sicher ist, dass in der Nähe des Ziels ein Parkplatz frei ist. Um dieses Problem zu vermeiden, wählt der Algorithmus einen Mittelweg, der das Paradox in sich ausgleicht.

Zufälle berücksichtigen

Für einen Autofahrer erscheint die Parkplatzsuche häufig wie ein Glücksspiel. Selbst in Gegenden mit vielen Parkplätzen kann der Fahrer Pech haben und keinen freien Parkplatz finden. Diese Zufälligkeit muss bei der Konzeption eines Parkassistenten berücksichtigt werden. Gleichzeitig gibt es aber

für manche Straßen auch ein spezifisches Vorwissen über die Wahrscheinlichkeit einen freien Parkplatz zu finden. Zum Beispiel ist die Wahrscheinlichkeit am Straßenrand einer Stadtautobahn parken zu können sehr gering, weil am Rand von Autobahnen in der Regel keine Parkplätze existieren.

Die drei Komponenten des Parkassistenten

Der Parkassistent kann als aktives lernendes System implementiert werden und hat im Wesentlichen drei interagierende Komponenten: **A. Speicher**, **B. Aktor** und **C. Lernalgorithmus**.

A. Im **Speicher** befindet sich das Wissen des Systems. Um die Zufälligkeit der Parkplatzbelegung zu berücksichtigen, wird das Wissen durch die Parameter eines probabilistischen Modells repräsentiert. Dieses Modell nimmt an, dass die Wahrscheinlichkeit in einem gegebenen Straßenabschnitt zu einer gegebenen Tageszeit parken zu können zwar unbekannt, aber (zumindest für einen längeren Zeitraum) fix ist. Wenn genügend Beobachtungen von Parkversuchen für einen Straßenabschnitt in einem bestimmten Zeitraum vorliegen, kann die Parkwahrscheinlichkeit durch die Häufigkeit der Parkerfolge abgeschätzt werden. Doch in der Regel liegen zu wenige Beobachtungen vor. Um auch in einem solchen Fall eine Aussage treffen zu können, bietet sich das Bayesian Framework

an. Seine Anwendung ermöglicht es, statt eines Punktschätzers für die Parkwahrscheinlichkeit (z. B. $p=0.35634356\dots$) eine Dichte über alle möglichen p -Werte anzugeben. Diese Dichte wird vom Lernalgorithmus abhängig von den Beobachtungen berechnet: Je mehr Beobachtungen vorliegen, desto stärker konzentriert sich die Dichte auf einen Wert und je weniger Punkte vorliegen, desto größer ist die Varianz der zur Dichte gehörenden Verteilung. Der Lernalgorithmus, der dieses leistet, ergibt sich aus dem Satz von Bayes. Die Dichte selbst ist durch zwei Parameter repräsentiert und diese Parameter repräsentieren das Wissen des lernenden Systems. Das System integriert also immer neue Beobachtungen in seinen Wissensstand. Es muss aber am Anfang, wenn noch keine Beobachtungen vorliegen, einen initialen Wissensstand vorweisen. Dieses initiale Wissen wird auch Vorwissen genannt. Das Vorwissen kann sehr konkret sein, wie im obigen Beispiel der Stadtautobahn, oder sehr vage. Das Vorwissen ist dann am vagsten, wenn jede Parkwahrscheinlichkeit von 0 bis 1 mit gleicher Wahrscheinlichkeit in Frage kommt (dies entspricht der Dichte der Uniformverteilung über $[0,1]$). Um Vorwissen für den Parkassistenten zu finden, lohnt es sich, sich noch einmal in die Situation eines ortsfremden Fahrers zu versetzen: Der ortsfremde Fahrer kann das Wissen, das er in anderen Städten gesammelt hat, auf die unbekannte Stadt übertragen, z. B. ist die Parkplatzsuche in dicht bebauten Wohngebieten

nach Feierabend in der Regel schwer. Um das Vorwissen des Parkplatzassistenten zu definieren, verwenden wir daher die Distanzen zu POIs, um eine Straße zu charakterisieren. Die POIs werden in einer Ontologie erfasst und mit Hilfe eines probabilistischen Modells wird eine initiale Dichte über die Parkwahrscheinlichkeiten errechnet.

B. Der **Aktor** hat die Aufgabe, dem Nutzer basierend auf dem aktuellen Wissensstand eine Suchroute vorzuschlagen. Die Definition dieses Aktors beeinflusst entscheidend, in wieweit die obigen zwei Ziele erreicht werden. Der Aktor nutzt das Prinzip des Thomson Samplings um einen Ausgleich zwischen den obigen zwei Zielen zu erreichen. Thomson Sampling ist eine besondere Art, das Wissen, das unser Assistent als Dichten über mögliche Parkwahrscheinlichkeiten modelliert, zu verwenden: Bevor der Aktor eine Aktion ausführt, wird von jeder Dichte über die Parkwahrscheinlichkeiten ein Sample gezogen.

C. Dieses Sample ergibt eine Straßenkarte mit möglichen Parkwahrscheinlichkeiten. Für diese Karte wird dann eine Parkplatzsuchroute berechnet. Hierfür existieren verschiedene Verfahren, etwa der Bellman Operator. Nachdem der Fahrer einen Parkplatz gefunden hat, werden die Beobachtungen mithilfe eines **Lernalgorithmus** in das probabilistische Modell integriert.

Computersimulation mit zwei Versuchsanordnungen

In einer Computersimulation wird ein Teil des Berliner Prenzlauer Bergs als Testgebiet definiert. Da es keine Daten über die tatsächlichen Parkwahrscheinlichkeiten gibt, werden diese mit einem geeigneten Verfahren ausgelost. Dazu wird der ungünstigste Fall hinsichtlich des Vorwissens betrachtet, nämlich der, dass es kein konkretes Wissen gibt. Für den Versuch wird angenommen, dass im Testgebiet 50 Parkplatzsuchen durchgeführt werden. Während dieser 50 Versuche wird das Wissen über die Parkwahrscheinlichkeiten immer weiter aktualisiert. Jede Suche wird durch ihren Ausgangspunkt und ihren Zielpunkt bestimmt. Da in der Simulation nur ein Kartenausschnitt betrachtet wurde, befinden sich die Ausgangspunkte auf den Straßen am Rande des Gebiets und die Zielpunkte innerhalb des Gebiets.

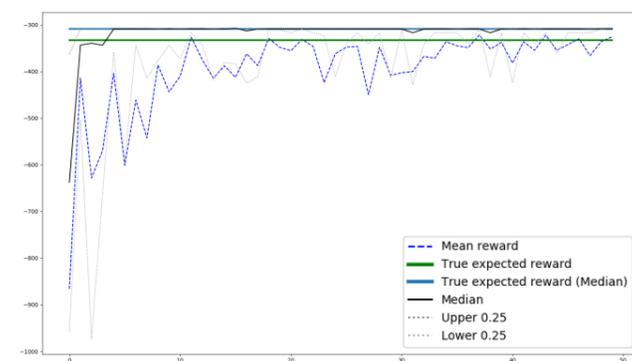


Abb. 1: Mittlere Suchdauer abhängig von der Anzahl der Parkversuche (wobei Start und Ziel über alle 50 Versuche fix sind)

Dabei werden zwei Versuchsanordnungen betrachtet:

1. Eine Suche wird mehrmals durchgeführt, d. h. ein Fahrer versucht mehrmals von einem fixen Ausgangspunkt zu einem fixen Ziel zu fahren.
2. Für jede der 50 Suchen wird ein anderes Ziel und ein anderer Ausgangspunkt ausgelost.

In den Versuchsanordnungen sind zwei Größen von Interesse: **Suchdauer** und **Wissensstand**, wobei die erste Versuchsanordnung verwendet wird, um die Suchdauer zu untersuchen, da bei zufälliger Wahl von Start und Ziel die Suchdauern alleine schon aufgrund dieser Parameter schwanken. Die **Suchdauer** setzt sich zusammen aus der Fahrdauer und dem anschließenden Fußweg. Diese Suchdauer ist selbst bei Kenntnis der tatsächlichen

Parkwahrscheinlichkeiten zufällig. Es ist also interessant, wie lange die Suche im Mittel dauert. Um den Lernfortschritt zu untersuchen, werden diese Größen als Funktionen der Versuchsanzahl betrachtet. *Abbildung 1* zeigt, dass mit steigender Versuchsanzahl die mittlere Suchdauer sinkt. Der Vergleich zwischen dem Median und dem Mittel der Suchdauer zeigt, dass anfangs der Mittelwert sehr stark von Ausreißern, d. h. außergewöhnlich langen Suchen, beeinflusst wird.

Bei der zweiten Versuchsanordnung wird der **Wissenszuwachs** betrachtet. Hier wird die Varianz der Verteilungen über die Parkwahrscheinlichkeiten als das Maß für Wissen verwendet. Je kleiner diese Varianz ist, desto sicherer ist sich der Algorithmus. *Abbildung 2* zeigt Statistiken über die Varianz der Parkwahrscheinlichkeiten. Die Gesamtheit, auf die sich diese Statistiken beziehen, sind alle Straßenabschnitte des Testgebiets. Mit

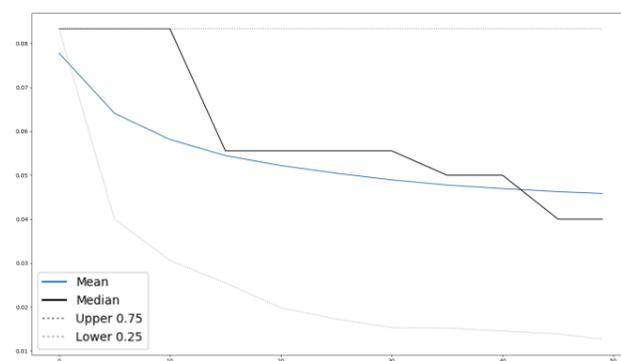


Abb. 2: Statistiken (bezogen auf das Versuchsgebiet) über die Varianz der Straßen

zunehmender Versuchszahl sinkt die Varianz, was bedeutet, dass das Wissen wächst. Besonders interessant sind hier die Quantile: Das 50 Prozent Quantile ist der Varianzwert für den die Hälfte der Straßen eine größere Varianz und die andere Hälfte eine kleinere Varianz besitzt. Die niedrigeren Quantile sinken mit der Anzahl der Parkversuche, wobei das 25 Prozent Quantil schneller sinkt als das 50 Prozent Quantil.

Ausblick

Damit KI-Systeme zuverlässig funktionieren, werden viele und vor allem qualitativ hochwertige Daten benötigt. In vielen Situationen liegen aber nicht genug Daten vor. Im GEISER Projekt wurde eine Lösung erarbeitet, die es KI-Systemen ermöglicht, auch mit kleinen Datenmengen anwendungstaugliche Ergebnisse zu produzieren. Dabei steht das maschinelle Lernen im Fokus: So kann der intelligente Parkassistent trotz geringer Datengrundlage seine Prognosen zu wahrscheinlich freien Parkplätzen fortlaufend verbessern. Je länger der Assistent im Einsatz ist, desto zuverlässiger wird er. Dieser Ansatz ist innovativ, weil er in allen Szenarien zum Einsatz kommen kann, in denen es an Daten mangelt.

Über das Fraunhofer IAIS

Als Teil der größten Organisation für anwendungsorientierte Forschung in Europa ist das Fraunhofer-Institut für Intelligente Analyse- und Informationssysteme IAIS mit Sitz in Sankt Augustin bei Bonn eines der führenden Wissenschaftsinstitute auf den Gebieten Künstliche Intelligenz, Maschinelles Lernen und Big Data in Deutschland und Europa. Mit seinen rund 300 Mitarbeitenden unterstützt das Institut Unternehmen bei der Optimierung von Produkten, Dienstleistungen, Prozessen und Strukturen sowie bei der Entwicklung neuer digitaler Geschäftsmodelle. Damit gestaltet das Fraunhofer IAIS die digitale Transformation unserer Arbeits- und Lebenswelt.

Über GEISER

Das Forschungsprojekt GEISER wurde vom Bundesministerium für Wirtschaft und Energie (BMWi) gefördert und im Jahr 2019 abgeschlossen. In dem Konsortium, bestehend aus Großunternehmen sowie kleinen und mittleren Unternehmen, wurde eine offene, cloudbasierte Plattform zur Akquise, Transformation, Speicherung, Integration, Qualitätssicherung, Verarbeitung und Auslieferung von auf Geo- und Sensordaten basierenden Diensten entwickelt. Die beteiligten Partner waren USU Software AG, Universität Leipzig, YellowMap AG, metaphacts GmbH, Fraunhofer-Institut für Intelligente Analyse- und Informationssysteme IAIS und TomTom. www.projekt-geiser.de

Literatur

- 1 Schmickler, Marion. *Jedes dritte Auto auf Parkplatzsuche*. Tagesschau 23.03.2019, URL: <https://www.tagesschau.de/inland/verkehrswende-interview-101.html>, abgerufen am 12.09.2019.
- 2 Agrawal, Ajay, Joshua Gans, and Avi Goldfarb. *Prediction machines: the simple economics of artificial intelligence*. Harvard Business Press, 2018.
- 3 Taddy, Matt. *The technological elements of artificial intelligence*. No. w24301. National Bureau of Economic Research, 2018.



Über den Autor

Dr. Alexander Kister arbeitet als Data Scientist am Fraunhofer IAIS. Er beschäftigt sich mit der Anwendung von Neuronalen Netzen, probabilistischen Modellen sowie datengetriebenen Optimierungsmethoden im autonomen Fahren und der Industrie 4.0.