

Christian Joachim Gruber / Iris Eisenberger¹⁾

Wenn Fahrzeuge selbst lernen: Verkehrstechnische und rechtliche Herausforderungen durch Deep Learning?

- I. Einleitung
- II. Was muss ein autonomes Fahrzeug können?
- III. Algorithmen bei autonomen Fahrzeugen
- IV. Deep Learning bei autonomen Fahrzeugen
 - A. Unterschiedliche Deep Learning Ansätze
 - B. Verkehrstechnische und rechtliche Herausforderungen
 - 1. Exaktheit bei der Abbildung von Regeln
 - 2. Abbildbarkeit von verkehrlichen Erfahrungswerten
 - 3. Abbildbarkeit von allgemeinen Lebenserfahrungen
 - 4. Blackbox: Qualitätssicherung und Kontrolle
- V. Schlussbemerkungen

I. Einleitung

Im Jahr 2010 hat Google sein selbstfahrendes Fahrzeugprojekt präsentiert.²⁾ Seit diesem Zeitpunkt ist autonomes Fahren³⁾ ein öffentlich verstärkt wahrgenommenes Thema.⁴⁾ Google hat das Jahr 2020 als Projektziel für eine Imple-

¹⁾ Für die Hilfe bei der Recherche und der Ergänzung des Fußnotenapparats danken wir Frau *Sophia San Nicolò*.

²⁾ Siehe *Google*, *What we're driving at*, 9. 10. 2010, <https://googleblog.blogspot.co.at/2010/10/what-were-driving-at.html> (23. 2. 2017); *Markoff*, *Google Cars drive themselves*, in *Traffic*, *The New York Times*, 9. 10. 2010, <http://www.nytimes.com/2010/10/10/science/10google.html> (23. 2. 2017).

³⁾ Wenn in diesem Beitrag von autonomen Fahrzeugen die Rede ist, sind sowohl automatisierte als auch autonome Fahrzeuge gemeint.

⁴⁾ Siehe zB: *Bundesministerium für Verkehr, Innovation und Technologie*, *Automatisiert – Vernetzt – Mobil: Aktionsplan Automatisiertes Fahren* (2016); *Sulzbacher*, *Österreich bekommt 2016 Teststrecken für selbstfahrende Autos*, *Der Standard.at*, 27. 8. 2015, <http://derstandard.at/2000021354958/Oesterreich-bekommt-2016-Teststrecken-fuer-selbstfahrende-Autos> (23. 2. 2017); *Deutsches Bundesministerium für Verkehr und digitale Infrastruktur*, *Strategie automatisiertes und vernetztes Fahren*, <http://www.bmvi.de/SharedDocs/DE/Publikationen/StB/broschuere-strategie-automatisiertes-vernetztes->

mentierung autonomer Fahrzeuge auf öffentlichen Straßen definiert.⁵⁾ Auch wenn ein Großteil der technischen Fortschritte nicht wissenschaftlich publiziert wurde, ist der Entwicklungsstand aus unterschiedlichen Statusberichten und Unfallberichten (zB monatliche Projektbegleitung von Google)⁶⁾ ableitbar.

Der vorliegende Beitrag beschäftigt sich mit dem Einsatz der Deep Learning⁷⁾ Methode bei autonomen Fahrzeugen⁸⁾ und mit ausgewählten verkehrstechnischen und rechtlichen Herausforderungen, die deren Einsatz mit sich bringt. In einem ersten Schritt wird zunächst dargelegt, was ein autonomes Fahrzeug können muss (II.) und welche Rolle Algorithmen in diesem Zusammenhang spielen (III.). Kern des Beitrages sind Ausführungen zu Deep Learning bei autonomen Fahrzeugen (IV.), wobei zunächst unterschiedliche Deep Learning Methoden (A.) und dann ausgewählte verkehrstechnische und rechtliche Problemstellungen (B.) dargestellt werden; konkret die Frage der Exaktheit bei der Abbildung von Regeln (1.), die Abbildungsmöglichkeiten verkehrlicher (2.) und allgemeiner (Lebens)Erfahrungen (3.) sowie die Qualitätssicherung und Kontrolle trotz einer Blackbox (4.). Ein Blick in die nähere Zukunft autonomer Fahrzeuge ist Bestandteil der Schlussbemerkungen (V.).

II. Was muss ein autonomes Fahrzeug können?

Um ein ausgewähltes Ziel erreichen zu können, muss ein autonomes Fahrzeug unterschiedliche Aufgaben erfüllen. Es soll zunächst seine Position im Straßenraum selbstständig erkennen; dh zum einen bestimmen, wo es sich global befindet und zum anderen, wo genau es sich auf der Straße aufhält (zB auf welchem Fahrstreifen) oder, wo es sich hinbewegt.⁹⁾ Positionsbestimmungen

fahren.pdf? (23. 2. 2017); Dobrindt plant rechtliche Grundlage für autonomes Fahren, Zeit Online, 18. 7. 2016, <http://www.zeit.de/mobilitaet/2016-07/bundesregierung-alexander-dobrindt-autonomes-fahren-gesetz> (23. 2. 2017); Freie Fahrt voraus, Süddeutsche Zeitung, 26. 1. 2015, <http://www.sueddeutsche.de/auto/autonomes-fahren-freie-fahrt-voraus-1.2321086> (23. 2. 2017).

⁵⁾ Siehe *APA*, Google will selbstfahrende Autos 2020 auf den Markt bringen, Der Standard.at, 15. 1. 2015, http://derstandard.at/2000010433306/Google-will-selbstfahrende-Autos-2020-auf-den-Markt-bringen_23.2.2017; *Halleck*, Google Inc. Says Self-Driving Car Will Be Ready By 2020, International Business Times, 14. 1. 2015, <http://www.ibtimes.com/google-inc-says-self-driving-car-will-be-ready-2020-1784150> (23. 2. 2017).

⁶⁾ Siehe zB *Google*, Self-Driving Car Project Monthly Report October 2016, <https://static.googleusercontent.com/media/www.google.com/de//selfdrivingcar/files/reports/report-0916.pdf> (23. 2. 2017).

⁷⁾ Zur Deep Learning Methode siehe zB *Rusk*, Deep Learning, Nature Methods 2016, 35; *LeCun/Bengio/Hinton*, Deep Learning, Nature 2015, 436.

⁸⁾ Siehe hierzu sowie zur Terminologie in der Fahrzeugautomatisierung *I. Eisenberger/Gruber/Huber/Lachmayer*, Automatisiertes Fahren – Komplexe regulatorische Herausforderungen, ZVR 2016, 383 ff.

⁹⁾ *Cacilo/Schmidt/Wittlinger/Herrmann/Bauer/Sawade/Doderer/Hartwig/Scholz*, Hochautomatisiertes Fahren auf Autobahnen – Industriepolitische Schlussfolgerungen, Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO, Dienstleistungsprojekt 15/14 (2015) 23.

dieser Art erfolgen primär über GPS-Daten.¹⁰⁾ Für eine größere Genauigkeit greifen einzelne Systeme (wie zB jenes von Google/Waymo)¹¹⁾ auf gescannte High-Definition Straßenkarten zu.¹²⁾ Dies ermöglicht eine auf Zentimeter genaue Ortsbestimmung im Straßenraum.¹³⁾

Neben der Positionsbestimmung muss das autonome Fahrzeug auch Objekte in seinem Umfeld erkennen können. Dies sind zunächst Verkehrsteilnehmer, wie zB fahrende oder stehende Fahrzeuge, Radfahrer oder Fußgänger. Die Objekterkennung umfasst auch die Straßenausstattung, wie etwa Verkehrszeichen, Wegweisungen, Bodenmarkierungen oder Verkehrslichtsignalanlagen. Hinzu kommen noch alle sonstigen Objekte, wie beispielsweise Bäume, Tiere oder auch rollende Fußbälle. Diese Objekte erkennt das Auto über unterschiedliche Systeme, beispielsweise Kameras, Ultraschall, Radar oder Lidar.¹⁴⁾

Aus all diesen Informationen ermittelt das autonome Fahrzeug jenen Bereich, der ein rechtskonformes, konfliktfreies und fahrdynamisch optimiertes Fahren ermöglicht.¹⁵⁾ Innerhalb dieser Bereichsabgrenzung berechnet es mögliche Fahrwege, um den besten davon auszuwählen und umzusetzen. Diese Fahrwegplanung erfolgt über einen Fahralgorithmus.¹⁶⁾

Der ermittelte Fahrweg muss nun in reale Steuerungshandlungen des Fahrzeuges übersetzt werden; beispielsweise Änderung der Fahrtrichtung, Beschleunigung oder Bremsung.¹⁷⁾ Auch dieser Schritt erfolgt über den Algorithmus, der die notwendigen Parameter für die Steuerung (virtuelle/digitale Lenkrad-, Gaspedal- und Bremspedalstellung) liefert.¹⁸⁾

¹⁰⁾ *Anderson/Kalra/Stanley/Sorensen/Samaras/Oluwatola*, Autonomous Vehicle Technology: A Guide for Policymakers, Rand Transportation, Space, and Technology Program (2016) 63 f. Siehe idZ auch *Kunnert* in diesem Band.

¹¹⁾ Siehe <https://www.waymo.com/> (23. 2. 2017).

¹²⁾ Siehe zB *Nvidia*, <http://www.nvidia.de/object/hd-mapping-system-de.html> (23. 2. 2017); Greis, Wer hat die besten Karten? *golem.de*, <https://www.golem.de/news/autonomes-fahren-wer-hat-die-besten-karten-1509-115506.html> (23. 2. 2017).

¹³⁾ Zur Problematik der Aktualität des Kartenmaterials und möglichen Straßenverlaufsänderungen siehe *Widmann* in diesem Band.

¹⁴⁾ Siehe zB *dpa*, Selbstfahrende Autos: Diese Technologien stecken in autonom fahrenden Autos, *Automobilwoche*, 29. 12. 2015, <http://www.automobilwoche.de/article/20151229/AGENTURMELDUNGEN/312299971/selbstfahrende-autos-diese-technologien-stecken-in-autonom-fahrenden-autos> (23. 2. 2017).

¹⁵⁾ *Schraube*, Die automatisierte Vernunft, der Freitag, 29. 7. 2014, <https://www.freitag.de/autoren/marian-schraube/die-automatisierte-vernunft-i> (23. 2. 2017); *Dietmayer*, Prädiktion von maschineller Wahrnehmungsleistung beim automatisierten Fahren, in *Maurer/Gerdes/Lenz/Winner* (Hrsg.), *Autonomes Fahren* (2015) 419.

¹⁶⁾ *Katrakazas/Quddus/Chen/Deka*, Real-time motion planning methods for autonomous on-road driving: State-of-the-art and future research directions, *Transportation Research Part C: Emerging Technologies* 2015, 416.

¹⁷⁾ *Falcone/Borrelli/Asgari/Tseng/Hrovat*, A model predictive control approach for combined braking and steering in autonomous vehicles, *Mediterranean Conference on Control & Automation* (2007) 1.

¹⁸⁾ *Sandström/Lampsijärvi/Holmström/Maconi/Ahmadzai/Meriläinen/Hæggström/Forsman*, Detecting lane departures from steering wheel signal, *Accident Analysis & Prevention* 2017, 272.

III. Algorithmen bei autonomen Fahrzeugen

Algorithmen (Programmcodes) steuern den zuvor beschriebenen Handlungsablauf. Dabei werden Sensor-Input-Daten in Steuerungs-Output-Daten transformiert. Bei der klassischen, regelbasierten Methode wird dieser Prozess Schritt für Schritt programmiert.¹⁹⁾

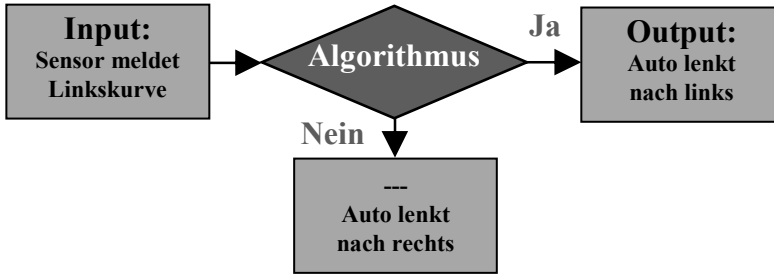


Abbildung 1: Allgemeiner Algorithmus (Beispiel Fahrzeugsteuerung)
Quelle: Christian Joachim Gruber (GNU Free Documentation License)

Softwareentwickler (Menschen) definieren Regeln und Bedingungen, wie die Fahrzeuge in bestimmten Situationen fahren und sich verhalten müssen. Ziel ist es, dass sich das autonome Fahrzeug mit den übrigen Verkehrsteilnehmern und sonstigen Objekten im Straßenraum im Einklang befindet.

Eingangsrahmenbedingungen sind dabei in Österreich in erster Linie einschlägiges Recht (zB die StVO,²⁰⁾ theoretisch auch einschlägige Judikatur²¹⁾ aber auch die Richtlinien und Vorschriften für das Straßenwesen (RVS)²²⁾. Dabei bleiben etliche Interpretations- und Handlungsspielräume.²³⁾ Als Beispiel sei

¹⁹⁾ Koga/Okuda/Tazaki/Suzuki/Haraguchi/Kang, Realization of different driving characteristics for autonomous vehicle by using model predictive control, Intelligent Vehicles Symposium IV (2016).

²⁰⁾ Bundesgesetz vom 6. Juli 1960, mit dem Vorschriften über die Straßenpolizei erlassen werden (Straßenverkehrsordnung 1960 – StVO 1960), BGBl 1960/159 idF BGBl I 2017/6.

²¹⁾ ZB OGH 2Ob135/11h, wonach von den beiden Vorrangregelungen des § 19 Abs 4 StVO und des § 19 Abs 6a StVO die „eindeutigere Vorrangregel der erstgenannten Bestimmung der komplexeren der zweitgenannten vorgehe“; konkretisierend zu § 17 Abs 1 StVO wird in der Judikatur ausgeführt, dass „Vorbeifahren im Abstand von nur siebenundzwanzig bis zweiunddreißig Zentimeter [...] bei einer Geschwindigkeit von fünfzig km/h unzulässig“ (OGH 2 Ob 65/80) sei, während „ein Seitenabstand von 40 cm bei einer Geschwindigkeit von 5 km/h“ (OGH 8 Ob 130/77) und allgemein „bei einem langsamen Vorbeifahren an abgestellten Fahrzeugen ein Abstand von 40 bis 50 cm“ (zB OGH 2 Ob 262/05a) ausreichend seien.

²²⁾ Österreichische Forschungsgesellschaft Straße-Schiene-Verkehr (FSV), Richtlinien und Vorschriften für das Straßenwesen, <http://www.fsv.at/shop/produktliste.aspx?ID=76b8e427-d3b2-4c25-8baa-00ae618e258e> (23. 2. 2017).

²³⁾ Siehe die bei Widmann in diesem Band angeführten Beispiele.

hier die gewählte Zeitlücke beim Einbiegen mit Querverkehr erwähnt. Wie diese Spielräume ausgefüllt werden, hängt vom jeweiligen Programmierer bzw Projektteam ab, aber auch von der Herstellerphilosophie (zB sportliche)²⁴⁾ oder besonders sichere Fahrweise)²⁵⁾. Persönliche Erfahrungen und Werthaltungen des Programmierers, des Projektteams und des Unternehmens rücken dabei verstärkt in den Fokus und werden somit integraler Teil des Programmcodes.

Zentral ist, dass Menschen diese Algorithmen bestimmen und definieren. Regelbasierte Algorithmen sind in Form von Entscheidungsbäumen aufgebaut (Ereignis A erzwingt eine Reaktion B). Dies bedeutet, dass jede Entscheidungskette des autonomen Fahrzeuges eindeutig vorprogrammiert und reproduzierbar ist. Diese klassische Form des Programmierens wird derzeit noch von den meisten Autoherstellern bei der Entwicklung autonomer Fahrzeuge eingesetzt.




Abbildung 2: Beispiel eines Entscheidungsbaumes eines regelbasierten Algorithmus
Quelle: <http://www.texample.net/tikz/examples/rule-based-diagram>
(GNU Free Documentation License)

Autofahren wird idR als wenig anspruchsvolle Tätigkeit wahrgenommen. Studien zeigen allerdings, dass auch Autofahren eine komplexe Gehirnaktivität erfordert,²⁶⁾ was sich dementsprechend auch beim Entwickeln von Fahr-

²⁴⁾ ZB BMW, „The Ultimate Driving Machine“.

²⁵⁾ ZB Volvo, „For Life“.

²⁶⁾ Vgl. Takahashi et al., Basic Study of Analysis of Human Brain Activities during Car Driving, in Human Interface and the Management of Information. Interacting with Information (2011) 627.

gorithmen gezeigt hat. Die große Menge an Eingangs- bzw. Sensordaten und die Vielfalt der verkehrlichen Konfliktmöglichkeiten führen in Summe zu unzähligen Kombinationsmöglichkeiten bzw. zu weitgefächerten Entscheidungsbäumen und somit zu einem umfangreichen und komplexen Programmcode.



Abbildung 3: Abhängigkeitsdiagramm eines komplexen Programmcodes
Quelle: <http://ora-00001.blogspot.co.at> (GNU Free Documentation License)

Komplexe Programmcodes sind systembedingt ressourcenaufwendig, wartungsintensiv und fehleranfällig.²⁷⁾ Die Fehleranfälligkeit eines Programms korreliert mit der Anzahl an Programmzeilen.²⁸⁾ Dies erschwert die Sicherung gewünschter Qualitätsstandards, was umso bedeutender ist, weil der Algorithmus schwerwiegende Entscheidungen zu treffen hat, mitunter solche, die über Leben und Tod entscheiden.²⁹⁾

Jeder Versuch, den Algorithmus zu verbessern, führt zu noch weiter verzweigten Entscheidungsbäumen und damit zu noch komplexeren Algorithmen; beispielsweise dann, wenn man bestimmte Kurven bei unterschiedlichen Wetterverhältnissen anders durchfahren soll. Dies hat die Forschung dazu veranlasst, nach neuen Methoden zu suchen,³⁰⁾ da die klassische Programmiermethode – langfristig gesehen – zum Scheitern verurteilt ist. Die derzeit erfolgversprechendste Methode ist Deep Learning.

²⁷⁾ *McCabe*, A Complexity Measure, IEEE Transactions on Software Engineering 1976, 308.

²⁸⁾ *Kan*, Complexity Metrics and Models (2003) 312.

²⁹⁾ Siehe idZ den Beitrag von *I. Eisenberger* in diesem Band.

³⁰⁾ *Pomerleau*, ALVINN, an autonomous land vehicle in a neural network (1989).

IV. Deep Learning bei autonomen Fahrzeugen

A. Unterschiedliche Deep Learning Ansätze

Im März 2016 schlug ein Computerprogramm (AlphaGo)³¹⁾ erstmals einen professionellen Go-Spieler im 9. Tan (Lee Sedol), und zwar 4:1.³²⁾ Das chinesische Brettspiel Go galt lange Zeit als die letzte Bastion der Menschheit.³³⁾ Kein Computerprogramm konnte professionelle Go-Spieler im 9. Tan bislang schlagen.³⁴⁾ Interessant daran ist, dass das Computerprogramm AlphaGo siegen konnte, weil es so programmiert wurde, dass es Go selbständig spielen lernt.³⁵⁾ Tausende Partien, die Menschen gespielt haben, spielte AlphaGo nach. Lernalgorithmen (Deep Learning) für künstliche neuronale Netze (Deep Neuronal Networks)³⁶⁾ machten dies möglich. Das ist für die Computerwissenschaften, aber auch für autonome Fahrzeuge ein – von der Allgemeinheit bislang weitgehend unbemerkt gebliebener – epochaler und disruptiver Entwicklungsschritt.³⁷⁾

Grundlage dafür sind künstliche neuronale Netze. Sie funktionieren ähnlich wie das menschliche Gehirn. Sie bestehen aus Neuronen, die in mehreren Schichten vernetzt sind.³⁸⁾

³¹⁾ *Chouard*, The Go Files: AI computer clinches victory against Go champion, *Nature*, 12. 3. 2016, <http://www.nature.com/news/the-go-files-ai-computer-clinches-victory-against-go-champion-1.19553#auth-1> (23. 2. 2017).

³²⁾ *Chouard*, The Go Files: AI computer wraps up 4-1 victory against human champion, *Nature*, 15. 3. 2016, <http://www.nature.com/news/the-go-files-ai-computer-wraps-up-4-1-victory-against-human-1.champion.19575> (23. 2. 2017).

³³⁾ Siehe zB *Dönges*, Das Go-Spiel ist geknackt, *Spektrum.de*, 28. 1. 2016, <http://www.spektrum.de/news/das-go-spiel-ist-geknackt/1397114> (23. 2. 2017).

³⁴⁾ Siehe zB *Beuth*, Google besiegt erstmals einen Go-Profi, *Zeit Online*, 28. 1. 2016, <http://www.zeit.de/digital/internet/2016-01/kuenstliche-intelligenz-google-deepmind-go-alphago>, (23. 2. 2017).

³⁵⁾ Ebenda.

³⁶⁾ Siehe *Silver et al*, Mastering the game of Go with deep neural networks and tree search, *Nature* 2016, 484.

³⁷⁾ Zum Konzept disruptiver Technologien siehe grundlegend *Christensen*, *The Inventor's Dilemma: When New Technologies Cause Great Firms to Fail* (1997); *Bower/Christensen*, *Disruptive Technologies. Catching the Wave*, *Harvard Business Review* 1995, 19; Beispiele früherer disruptiver Technologien sind etwa das Automobil, welches innerhalb kurzer Zeit um 1900 die Pferdekutsche verdrängte oder CDs und DVDs, die Ende des 20. bzw Anfang des 21. Jhds Schallplatten und VHS-Videobänder ersetzen

³⁸⁾ Siehe *McCulloch/Pitts*, A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biology* 1943, 115; *Minsky/Papert*, *Perceptrons. An Introduction to Computational Geometry* (1969).

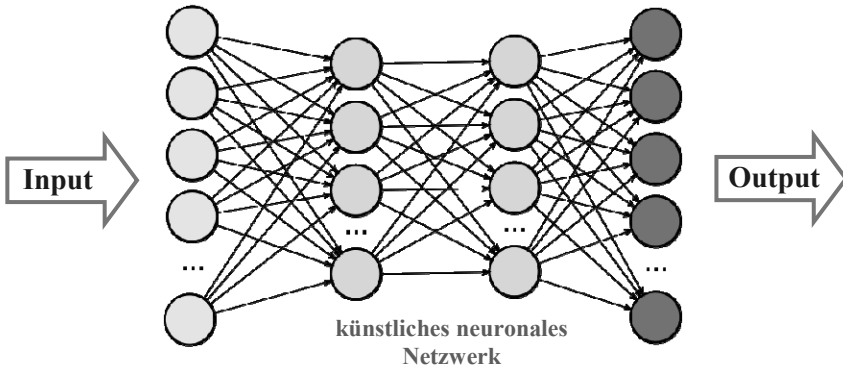


Abbildung 4: Schematische Darstellung eines künstlichen neuronalen Netzwerks
 Quelle: Christian Joachim Gruber (GNU Free Documentation License)

Damit neuronale Netze, wie die bei AlphaGo eingesetzten, Go erlernen können, müssen sie trainiert werden.³⁹⁾ Dafür gibt es unterschiedliche Methoden. Zwei für den Anwendungsbereich des autonomen Fahrens einsetzbare Methoden sind das Supervised und das Unsupervised Learning.⁴⁰⁾ Ein weiterer Ansatz, der hier nicht im Detail beschrieben werden soll, ist das Reinforcement Learning.⁴¹⁾ Bei Deep Learning wird der Algorithmus so zu sagen „erzogen“. Er wird für seine Fahrten benotet bzw. belohnt. Weicht das generierte Fahrverhalten vom gewünschten Fahrverhalten ab, wird die Fahrt negativ bewertet. Danach wird die Trainingsfahrt, mit dem Ziel die Belohnung zu erhöhen, wiederholt. Somit wird das Fahrverhalten im Laufe der Lernphase stetig optimiert. Bei dieser Methode können neben realen auch virtuelle Trainingsfahrten herangezogen werden.

Beim *Supervised Learning* hingegen ist eine Vielzahl von Inputdaten (Trainingsdaten), die in klassifizierter und bewerteter Form vorliegen, die Grundlage für die Generierung des Algorithmus. Dazu gehören etwa eine große Anzahl von Objektbildern (zB Radfahrer, Autos oder Häuser), bei denen klar ist, was klassifikatorisch abgebildet ist. Diese Bilder werden als Inputdaten dem Künstlichen Neuronalen Netzwerk eingespielt. Daraus entsteht ein Algorithmus, der

³⁹⁾ Siehe *Schmidhuber, My First Deep Learning System of 1991 + Deep Learning Timeline 1962–2013, CoRR 2013.*

⁴⁰⁾ Siehe zB *Wachsfeld/Winner, Lernen autonome Fahrzeuge?* in *Maurer/Gerdes/Lenz/Winner (Hrsg), Autonomes Fahren (2015) 465 (469 f).*

⁴¹⁾ Unter *Reinforcement Learning* versteht man Methoden maschinellen Lernens, bei der ein Agent aus der Interaktion mit seiner Umwelt lernt. Anstatt ihm explizit beizubringen, welche Aktion er wählen soll, erhält er in bestimmten Situationen Belohnungen für seine Aktionen und entwickelt selbständig Strategien, um diese Belohnungen zu maximieren; siehe grundlegend *Sutton/Barto, Reinforcement Learning: An Introduction (1998).*

selbstständig lernt, Objekte zu erkennen. Zeigt man diesem trainierten Fahralgorithmus bzw dem künstlichen neuronalen Netz ein neues, nicht in den Trainingsdaten enthaltenes, Bild, kann es beispielsweise den darauf abgebildeten Radfahrer als solchen selbstständig identifizieren. Ein Nachteil dieser Methode ist die benötigte Datenmenge; ein weiterer der Umstand, dass die benötigten Daten im Vorfeld manuell zu klassifizieren oder bewerten sind, was insgesamt sehr aufwendig und arbeitsintensiv ist.

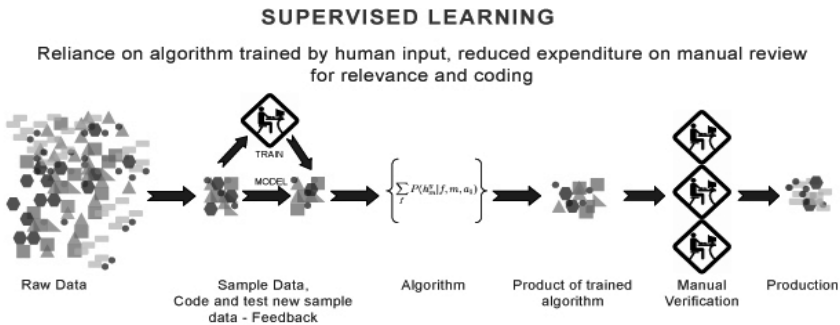


Abbildung 5: Supervised Learning bildlich dargestellt
Quelle und Copyright: Hudson Leagal, 2016

Beim *Unsupervised Learning* liegen für die Trainingsdaten keine im Vorfeld durchgeführten Klassifizierungen oder Bewertungen vor.⁴²⁾ Die Klassifizierung und Bewertung erfolgen allerdings über definierte Zielvorgaben, zB das Spiel Go zu gewinnen oder die Kurve so schnell oder so sicher wie möglich zu durchfahren.

Für die Objekterkennung auf den Bildern fehlen die notwendigen Klassifizierungen, wie beispielsweise Radfahrer oder Auto. Bei dieser Methode findet und klassifiziert der Lernalgorithmus Ähnlichkeiten bei den einzelnen Bildern selbstständig. Zeigt man dem trainierten Algorithmus ein neues, nicht in den Trainingsdaten enthaltenes, Bild, kann er dieses in eine abstrakte Klasse, zB A (das können Radfahrer sein) oder B (das können Autos sein) einteilen. Mit zusätzlichen Datenquellen (beispielsweise Bücher mit Illustrationen) lernt der Algorithmus auch die Klassen selbstständig zu benennen. Ein Nachteil dieser Methode ist, dass damit kaum Wertigkeiten, wie beispielsweise gut oder schlecht abbildbar sind. Das heißt, auch gutes oder schlechtes Fahrverhalten ist schwer zu beurteilen.

⁴²⁾ Siehe zB *Wachenfeld/Winner* (FN 38) 465 (469 f).

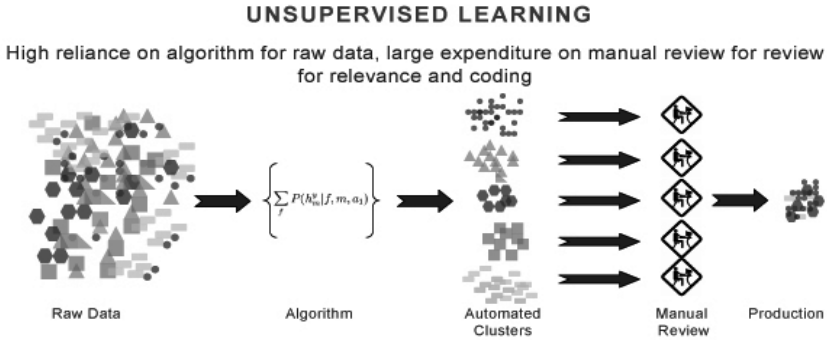


Abbildung 6: Unsupervised Learning bildlich dargestellt
Quelle und Copyright: Hudson Legal, 2016

Auf Basis dieser Deep Learning Methoden sind auch die Algorithmen für das autonome Fahren generierbar. Dies wird seit einigen Jahren erforscht⁴³⁾ und seit kurzem setzt auch Tesla Deep Learning bei der Generierung der Fahralgorithmen seiner Fahrzeuge ein.⁴⁴⁾

Deep Learning unterscheidet sich fundamental von der klassischen, manuell programmierten Methode. Es gibt keine eindeutig im Vorfeld definierten Entscheidungsbäume. Das Fahren wird anhand von echten Fahrten von Menschen erlernt. Dazu werden die Fahrdaten der Sensoren (zB Videoaufnahmen) und die Steuerungsdaten (Lenkeinschläge, Gas- oder Bremspedalstellungen) aufgezeichnet. Das sind im Ergebnis die Trainingsdaten für das künstliche neuronale Netz.

Wird Deep Learning bei autonomen Fahrzeugen eingesetzt, stehen nicht mehr die Programmierer und ihre Wertigkeiten, sondern die definierten Ziele, die gesammelten Daten und die Fahrer der Trainings-Inputdaten im Zentrum.

Ein Teil der benötigten Daten liegt in bewerteter Form vor. Menschen haben dazu die Fahrweisen der Trainingsfahrten nach unterschiedlichen Klassen (gut bis schlecht) bewertet. Mit dieser Qualität von Input-Daten kann der Lernansatz des Supervised Learning angewendet werden. Häufig vorkommende Verkehrs- und Konfliktsituationen können mit diesem Lernansatz sehr effektiv trainiert werden. Auch die Fahrdynamik ist mit dieser Methode gut erlernbar.

⁴³⁾ *Bojarski et al*, End to End Learning for Self-Driving Cars (2016); siehe auch folgendes Video zum Training neuronaler Netzwerke: <https://drive.google.com/file/d/0B9raQzOpiznlTkR1a241ZnBEcjQ/view> (23. 2. 2017); *Pomerleau* (FN 30).

⁴⁴⁾ Siehe zB <https://www.tesla.com/blog/all-tesla-cars-being-produced-now-have-full-self-driving-hardware>, Video dazu: <https://vimeo.com/188414442> (23. 2. 2017).

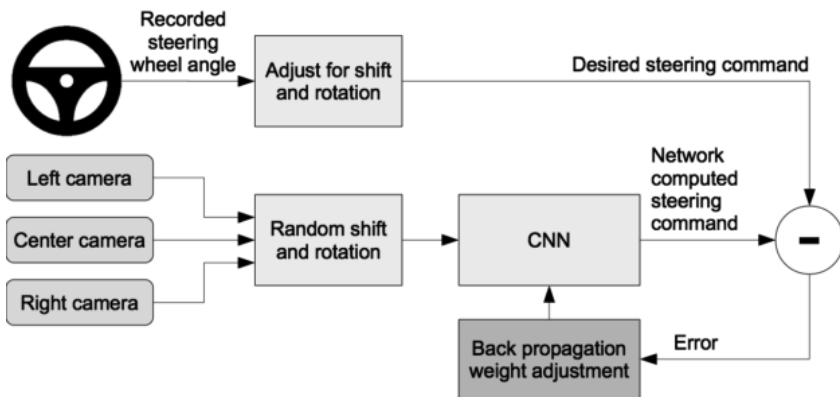


Abbildung 7: Generieren eines Fahralgorithmus (in diesem Beispiel ein Convolutional Neural Network, CNN) mittels Deep Learning
 Quelle: Nvidia Corporation, End to End Learning for Self-Driving Cars, arXiv:1604.07316, Homdel, NJ, 2016

Für das Erlernen der Fahrdynamik müssen die Fahrdaten allerdings nicht zwingend in einer bewerteten Form vorliegen. Hier ist auch das Unsupervised Learning einsetzbar. Unterschiedliche Fahrprofile (beispielsweise dynamisch, komfortabel) sind auf diese Weise identifizierbar. Diese können als einstellbare Parameter im Fahralgorithmus integriert werden.

Das Ergebnis ist ein autonomes Fahrzeug, welches sich im Anwendungsfall ähnlich wie seine Trainer (Durchschnitt aller Fahrer von den Trainingsdaten) verhält. Theoretisch sogar besser, weil diese Algorithmen so ausgelegt sind, dass sie das vermeintlich optimale Fahrverhalten prioritär übernehmen sollen (dh ein mit Daten von Formel 1 Piloten trainierter Fahralgorithmus würde beispielsweise bei regennasser Straße fahren wie Fernando Alonso und bei trockener wie Kimi Räikkönen).

Beim Lernansatz Supervised Learning nehmen diese Bewertungen noch Menschen vor; beim Unsupervised Learning muss der Algorithmus aus den Zielvorgaben und den vorliegenden Daten selbst seine Bewertungen generieren. Dabei werden zB Fahrten mit Verkehrsübertretungen bewusst ausgeschieden. Bei dieser Methode werden auch die Verkehrsregeln der StVO sowie die Inhalte der RVS indirekt über den Lernvorgang implementiert. Um das Erlernen all dieser Regeln annähernd gewährleisten zu können, sind systembedingt eine große und qualitativ hochwertige Datenmenge (Big Data) notwendig.⁴⁵⁾ Diese können von Testfahrern, aber auch von den Kunden der Fahrzeughersteller generiert werden.

⁴⁵⁾ *Kirkpatrick et al*, Overcoming catastrophic forgetting in neural networks (2017), arXiv:1612.00796v2.

Im Ergebnis kommt es beim Einsatz von Deep Learning bei autonomen Fahrzeugen zu einer Fokusverschiebung. Weg von der manuellen Logik der klassischen Methode hin zu den Lerninputdaten; trainiert wird mit Lerninputdaten und den darin enthaltenen Handlungen. Während die Zielvorgaben wie bei der klassischen Methode vom Programmierer bzw Projektteam oder vom Unternehmen vorgegeben werden, kommen beim Deep Learning die Wertigkeiten nicht vom Programmierer, sondern aus den vorgesetzten Daten. Die Quantität und Qualität der Daten spielt daher bei dieser Deep Learning Methode eine zentrale Rolle.

Derzeit wird mit einer Kombination aus der Supervised und Unsupervised Methode gearbeitet, ergänzt um die Prinzipien der Reinforcement Methode.

B. Verkehrstechnische und rechtliche Herausforderungen

Der Einsatz von Deep Learning bei autonomen Fahrzeugen ist sowohl verkehrstechnisch als auch rechtlich herausfordernd; insbesondere bei der Qualitätssicherung sind andere Wege zu suchen als beim klassischen Programmieren. Zunächst stellt sich die Frage, wie exakt festgeschriebene Regeln (zB StVO) umsetzbar sind.⁴⁶⁾ Weiters muss geklärt werden, wie verkehrliche Erfahrungswerte und allgemeine Lebenserfahrungen abgebildet werden können. Schließlich ist fraglich, wie bei autonomen Fahrzeugen, die nach der Deep Learning Methode trainiert sind, überprüft/gewährleistet werden kann, dass autonome Fahrzeuge Regeln einhalten und sicher sind.

1. Exaktheit bei der Abbildung von Regeln

Da Deep Learning Fahralgorithmen primär durch bestehende reale Fahrdaten generiert werden, fließen das Fahrverhalten und damit die Regelkonformität, aber auch der Regelbruch mit in den Algorithmus ein; die exakte Abbildbarkeit wird dadurch zur Herausforderung. Hier liegt der zentrale Unterschied zur klassischen Methode, bei der die exakte Abbildbarkeit der Regeln durch die Eingabe der Parameter großteils gewährleistet wird; auch wenn hier nicht übersehen wird, dass die exakte Regelabbildung bei der klassischen Programmiermethode ebenfalls problematisch ist.⁴⁷⁾

Die Deep Learning Methode macht den Algorithmus aber mit dem Menschen vergleichbar. Er kann lernen, und zwar richtiges und falsches Verhalten und er reproduziert auch beides. Das Problem, dass nicht nur richtiges, sondern mitunter falsches Verhalten erlernt und Letzteres auch reproduziert wird, ist durch quantitative und qualitative Trainingsdaten reduzierbar. Ein Restrisiko wird allerdings, wie beim Menschen, bleiben. Dies führt zu verkehrstechnischen, aber auch rechtlichen Herausforderungen.

Aus verkehrstechnischer Sicht sollten die Trainingsdaten in einem ersten Schritt eine statistisch signifikant hohe Anzahl an regelkonformen Fahrweisen

⁴⁶⁾ Dass das auch ein Problem bei der klassischen Programmiermethode ist, beschreibt *Widmann* in diesem Band.

⁴⁷⁾ Etwa wegen der großen Fülle an Regeln, die relevant werden können oder weil diese oft nicht eindeutig sind.

enthalten. Dies kann zB durch eine manuelle Vorselektion (inkl Bewertung der Inputdaten) gewährleistet werden. Das Ergebnis ist ein annähernd regelkonformes Fahren. Annähernd deshalb, weil nicht alle potentiellen Konfliktsituationen in den Trainingsdaten enthalten sein können; weil die Datenmengen so groß sind, dass Fehler übersehen oder menschliche bzw algorithmische Bewertungen falsch vorgenommen werden. Der Mensch befolgt in der Praxis nicht alle Regeln. Hinzukommt, dass die Regeln nicht immer eindeutig sind. Die Trainingsdaten können demnach fehlerbehaftet sein. Es ist mit dieser Methode jedenfalls schwer zu gewährleisten, dass die StVO vollständig integriert wird.⁴⁸⁾

Es sollte jedenfalls sichergestellt werden, dass zumindest die sicherheitsrelevanten Regelungen der StVO im Algorithmus abgebildet sind. Diese könnten mittels klassischer Programmiermethode im Fahralgorithmus integriert werden. Diese Teile des Algorithmus würden als Zwischenebene fungieren und die mittels Deep Learning gelernten Fahrweisen im Notfall überstimmen. So könnte überprüft werden, ob mit der vom Algorithmus berechneten Fahrgeschwindigkeit auch wirklich die zulässige Höchstgeschwindigkeit (eventuell inkl einer definierten Toleranz) eingehalten wird.

Dass ein mit Deep Learning trainiertes Fahrzeug beinahe wie ein Mensch agiert, ist auch rechtlich herausfordernd. Zunächst stellt sich wie beim Menschen die Frage, wann das Fahrzeug ausreichend trainiert ist und für den Verkehr zugelassen werden kann. Es könnte eine Art Führerschein benötigt werden, der gewährleistet, dass das Fahrzeug für den Verkehr zugelassen werden kann. Denkbar wäre beispielsweise eine Art Produktzulassung, bei der eine staatliche Stelle das Fahrzeug für den Verkehr freigibt und regelmäßig auf seine Verkehrstauglichkeit überprüft. Dafür müsste festgelegt werden, ab wann ein Fahrzeug verkehrstauglich ist. Hier könnte beispielsweise vorgesehen werden, dass eine bestimmte Anzahl von Testszenarien/Testkilometern unfallfrei absolviert werden muss, bevor ein Auto auf die Straße darf. Eine Möglichkeit dies umzusetzen wären virtuelle Tests.

Die Einhaltung festgeschriebener Regelungen ist aber nicht nur bei der Zulassung, sondern auch dann relevant, wenn das Fahrzeug bereits im Verkehr eingesetzt wird. Menschen können bei regelwidrigen Verstößen bestraft werden oder es kann ihnen bei schwerwiegenden Verstößen auch die Lenkerberechtigung entzogen werden. Für autonome Fahrzeuge müsste es äquivalente Regulationsmechanismen geben. Bei geringfügigen Ordnungswidrigkeiten müssten ebenfalls Sanktionsmechanismen vorgesehen werden. Fraglich ist hier freilich, wer bestraft werden soll: zB der Fahrzeughalter, die Insassen oder der Fahrzeughersteller? Bei schwerwiegenden Verstößen ist denkbar, dass die Fahrzeuge aus dem Verkehr zu ziehen sind und erst wieder für den Verkehr zugelassen werden, wenn beispielsweise aufgrund eines Updates keine weiteren schwerwiegenden Regelbrüche mehr zu erwarten sind. Anzumerken ist allerdings, dass bei selbstlernenden Systemen auch das einzelne Fahrzeug eigene „Verhaltensmuster“ entwickeln würde. Die Bezugnahme auf die validierte Software-Version des Algorithmus für ein Softwareupdate wäre dann nicht möglich.

⁴⁸⁾ Siehe *Widmann* in diesem Band.

2. Abbildbarkeit von verkehrlichen Erfahrungswerten

Problematisch sind auch jene Verkehrsverhaltensentscheidungen, bei denen für kurze Zeit oder auch systematisch gesetzliche Regelungen gebrochen werden. Dazu gehört zB kurzfristiges Überfahren einer Sperrlinie, wenn man einen Fahrradfahrer mit einem größeren Sicherheitsabstand als notwendig überholt, oder auch, wenn man in der Stadt an einem parkenden Fahrzeug vorbeifahren muss, obwohl dieses vorschriftswidrig in die Fahrbahn ragt; auch fahrdynamische Verhaltensweisen, etwa das Ausnutzen der Fahrbahnbreite(n) in Kurven, also Verhaltensweisen, die sich die einzelnen Fahrer auf Grund der eigenen Fahrerfahrung im Laufe der Zeit angeeignet haben. Bei der Deep Learning Methode fließen somit automatisch diese „menschlichen Schwächen und Stärken“ in den Algorithmus mit ein. Es kommt damit zu keinem optimalen Algorithmus.

Dies wird vor allem in jener Übergangsphase relevant sein, wo autonome und menschlich gelenkte Fahrzeuge im Straßenverkehr parallel eingesetzt werden. Der Umstand, dass der Algorithmus kein optimaler ist und menschliche Schwächen und Stärken hat, macht die autonomen Fahrzeuge für die Menschen berechenbarer. Auch die Leistungsfähigkeit des Verkehrsnetzes kann somit erhalten bleiben, weil auch autonome Fahrzeuge etwa bei den zuvor genannten Beispielen Regeln übertreten werden und der Verkehrsfluss nicht deshalb ins Stocken gerät (Vermeidung von Kfz-Staubildung).

Problematisch kann die Übernahme von Erfahrungswerten dann sein, wenn es regional oder national bedingt unterschiedliche Fahrverhaltensweisen, verschiedene Rechtsvorschriften und Judikatur gibt. Lösbar wäre dieses Problem durch länderspezifische oder regionale Algorithmen.

3. Abbildbarkeit von allgemeinen Lebenserfahrungen

Auch unvorhersehbare Sondersituationen können im Straßenverkehr auftauchen. Für diese gibt es naturgemäß keine standardisierten Lösungen. Menschen lösen oder entschärfen solche Situationen regelmäßig intuitiv. Auch der Charakter kann aus mancherlei Pattsituation heraushelfen, zB wenn an einer Kreuzung in einer Konfliktsituation der Klügere nachgibt. Soziale Intelligenz und Empathie sind dabei entscheidend. Dieses menschliche Sekundärwissen, das sich ein Lenker in anderen Lebenssituationen angeeignet hat, wie beispielsweise beim Dreiradfahren, Fahrradfahren oder auch bei Computerspielen, kann in Gefahrensituationen hilfreich sein. Über Deep Learning kann dieses Sekundärwissen für die Nutzung beim Fahren schwer generiert werden.

Verkehrstechnisch ließe sich dieses Problem über die Quantität primärer Lerndaten entschärfen. Zusätzlich wäre es sinnvoll, die Lernprozesse um virtuelle Lernmethoden zu erweitern und Lernmethoden zu entwickeln, mit denen fahrfremde Daten in den Lernprozess implementiert werden können.⁴⁹⁾ Auch wenn der Algorithmus damit menschenähnlicher wird, bleibt der Mensch dennoch flexibler. Im Ergebnis bedeutet dies aber, dass sich das Auto in letzter Kon-

⁴⁹⁾ Siehe idZ auch *Fernando et al*, PathNet: Evolution Channels Gradient Descent in Super Neural Networks (2017), arXiv:1701.08734.

sequenz nicht vollständig an den Menschen anpassen wird können, sondern sich der Mensch an die Verhaltensweisen autonomer Fahrzeuge anpassen wird müssen.

Rechtlich wird dies auch Anpassungen erfordern; Anpassungen, die das menschliche Verhalten betreffen. Verhaltensweisen, die bislang erlaubt sind, könnten verboten oder zusätzliche Verhaltensweisen vorgeschrieben werden. Damit ein autonomes Fahrzeug etwa erkennen kann, dass ein Fußgänger die Straße überqueren will, könnte es notwendig sein, dass man beim Einsatz autonomer Fahrzeuge auf den Zebrastreifen treten kann, die Straße aber erst überqueren kann, wenn ein sich annäherndes Fahrzeug tatsächlich angehalten hat. Es wäre auch denkbar, dass künftig erst überquert werden kann, wenn der Fußgänger ein Handzeichen gibt, welches das autonome Fahrzeug decodieren kann. Gleichzeitig könnten auch Fahrzeuge „kommunizieren“, dass sie beispielsweise das Handzeichen „wahrgenommen“ haben.

4. Blackbox: Qualitätssicherung und Kontrolle

Die Qualität eines autonomen Fahrzeuges ist auf unterschiedliche Weise überprüfbar. Ein verfolgter Ansatz verwendet die Anzahl an fehlerfrei gefahrenen Kilometern oder verkehrstechnische Kennzahlen, wie beispielsweise die Unfallrate, als Zulassungskriterium. Eine weitere Möglichkeit ist es, die verwendeten Fahralgorithmen direkt über den Code zu prüfen. Diese Form der Prüfung kann zB bei der klassischen Programmiermethode angewendet werden. Rechtlich könnte man die Hersteller dazu verpflichten, den Code einer Prüfungsstelle offenzulegen,⁵⁰⁾ der diesen auf die notwendige Implementierung der StVO validiert.⁵¹⁾

Bei einem mittels Deep Learning trainierten Fahralgorithmus führt diese Prüfung ins Leere. Man kann diese Algorithmen ebenfalls offenlegen und der Code selbst bzw die Verknüpfungen des künstlichen neuronalen Netzes sind lesbar. Die Funktionsweise ist aber für den Prüfer bzw für Menschen nicht mehr nachzuvollziehen bzw zu erfassen. Um den Algorithmus zu überprüfen, müsste bei einem bestimmten Input (zB Kameras oder Sensoren) dem zu erwartenden Output (Soll-Fahrhandlung des autonomen Fahrzeuges) der berechnete Output (Ist-Fahrhandlung) gegenübergestellt werden. Je geringer die Abweichung, desto höher ist die Qualität des Fahralgorithmus zu bewerten.

Bei einem Fahralgorithmus, der über den Deep Learning Ansatz generiert wurde, erhält man demzufolge einen Code, der vom Menschen selbst nicht mehr oder nicht mehr im vollen Umfang erfasst oder gedeutet werden kann. Daher spricht man auch von einer nicht zu öffnenden Blackbox.⁵²⁾

⁵⁰⁾ Zu einer ähnlichen Forderung siehe auch *I. Eisenberger* und *K. Lachmayer* in diesem Band.

⁵¹⁾ Siehe idZ auch *Sammer/Röschel/Gruber*, Qualitätssicherung für die Anwendung von Verkehrsnachfragemodellen und Verkehrsprognosen, FSV Straßenforschungsheft 604/2012.

⁵²⁾ *Cauer*, Theorie der linearen Wechselstromschaltungen (1941).




Abbildung 8: Blackbox Problematik

Quelle: Christian Joachim Gruber (GNU Free Documentation License)

Aus verkehrstechnischer Sicht bedeutet dies, dass ein derartiges Fahrzeug deutlich umfangreichere Fahrprüfungen mit mehreren vordefinierten Testszenarien durchlaufen muss, weil man nicht auf Kausalitätswissen zwischen Input und Output zurückgreifen kann. Eine Qualitätssicherung, die diese Blackbox Problematik entschärft, muss daher mit einer quantitativen und qualitativen Auswahl von Testszenarien arbeiten. Systembedingt können diese Testszenarien trotzdem nur eine Teilmenge des realen Verkehrsablaufes abbilden, dh durch diese Form der Prüfung ist nur eine Teilsicherheit gewährleistet.

Im Vergleich zum Menschen wird dieses Problem zusätzlich verstärkt. Ein Mensch lernt laufend weiter, dh mit jedem zusätzlich gefahrenen Kfz-Kilometer kommen neue Erfahrungen hinzu. Bei einem autonomen Auto bleibt der Entwicklungsstand bis zum nächsten Softwareupdate auf demselben Niveau. Stellt der Hersteller ein Softwareupdate des Fahralgorithmus zur Verfügung, müsste dieser prinzipiell auch wieder das volle Prüfprogramm durchlaufen, um die Qualität des Algorithmus und in weiterer Folge auch die Sicherheit für alle anderen Verkehrsteilnehmer sicherstellen zu können.

Bei einem Verkehrsunfall können zwar die Rahmenbedingungen für diesen geklärt werden, der Grund oder die Rechtfertigung für die Fehlhandlung ist in den meisten Fällen jedoch nicht mehr nachvollziehbar.⁵³⁾ Die Ursache lag eventuell schon bei fehlerhaften Trainingsdaten, durch die für diese Situation beim Training eine falsche Reaktion in den Algorithmus aufgenommen wurde.

⁵³⁾ Der Begriff Blackbox wird unterschiedlich eingesetzt. Traditioneller Weise wird Blackbox für ein Gerät verwendet, das Daten speichert, beispielsweise bei einem Flugzeug (Der Prototyp des Flugdatenspeichers, die ARL Flight Memory Unit, wurde 1956 von Warren konzipiert; siehe idZ auch K. Lachmayer und Bruckmüller/Schumann in diesem Band). Auch bei autonomen Fahrzeugen soll diese Form der Blackbox eingesetzt werden, um Daten zu erfassen. Wenn hier von Blackbox die Rede ist, dann geht es um Vorgänge, die nicht rekonstruierbar sind.

Auch wenn diese Fahralgorithmen zu besseren autonomen Fahrzeugen führen werden, ist in einer demokratischen Gesellschaft zu fragen, ob und wie „Blackbox-Algorithmen“ im menschlichen Umfeld (zB Straßenverkehr) akzeptierbar sind. Schließlich steht am Ende ein Blackbox-Algorithmus, der im Einzelfall über Verletzungen oder im Extremfall über Leben und Tod in verkehrstechnischen Konfliktfällen entscheiden muss (Trolley Problem, Dilemmasituation)⁵⁴). Dies wirft ethische, gesellschaftspolitische und rechtliche Fragen auf, die in einem demokratischen Prozess zu klären sind. Wie tief und wie frei darf autonomen Fahrzeugen diese Entscheidungsgewalt überlassen werden, insb dann, wenn Menschen keinen exakten Einblick in den Entscheidungsablauf mehr haben; mit anderen Worten, Menschen die maschinellen Entscheidungen nicht mehr verstehen können. Die Folge wäre, dass etablierte Rechtsfiguren, wie Rechtfertigung, Verantwortlichkeit oder Zurechnung⁵⁵) zunehmend ihre zentrale Bedeutung für das Funktionieren eines Rechtssystems verlieren würden.⁵⁶)

All diese Fragen sind grundlegende gesellschaftspolitische, aber auch rechtliche Fragestellungen, die bereits im Vorfeld der Implementierung neuer Technologien zu diskutieren sind,⁵⁷) und zwar bevor die Gesellschaft vor vollendete Tatsachen gestellt wird.⁵⁸)

V. Schlussbemerkungen

Die Unterschiede zwischen klassischer Programmierung einerseits und der Deep Learning Methode andererseits wirken auf den ersten Blick so, als ob sie rein technischer Natur wären. Näher betrachtet, zeigt sich allerdings, dass ein tiefgreifender verkehrlicher, gesellschaftlicher und regulatorischer Paradigmenwechsel bevorsteht.

Künftig programmiert nicht der Programmierer oder sein Team Entscheidungen, sondern eine Maschine lernt zu entscheiden (zB Fahrmanöver wie bremsen oder beschleunigen). Sie generiert einen Programmcode, dessen Entscheidungen weder im Rahmen der Entwicklung noch beim Fahreinsatz vollständig nachvollziehbar sind: eine nicht mehr offenbare Blackbox entsteht. Sollte schließlich bei der Algorithmengenerierung verstärkt auf eine virtuelle Reinforcement Deep Learning Methode gesetzt werden, enthumanisiert dies das autonome Fahren noch ein Stück weiter. Damit intensivieren sich die in diesem Beitrag aufgezeigten Probleme zusätzlich.

⁵⁴) Siehe *I. Eisenberger* in diesem Band.

⁵⁵) Siehe idZ auch die Beiträge von *Harnoncourt* und *Bruckmüller/Schumann* in diesem Band.

⁵⁶) Zu ähnlichen Überlegungen siehe *Spiecker genannt Döhmann*, Zur Zukunft systemischer Digitalisierung – Erste Gedanken zur Haftungs- und Verantwortungszuschreibung bei informationstechnischen Systemen, CR 2016, 696

⁵⁷) Im Sinne eines *legal foresights*. S zu ähnlichen Forderungen auch *Bruckmüller/Schumann* in diesem Band.

⁵⁸) Siehe *I. Eisenberger*, Innovation im Recht (2016).

Beim mittels Deep Learning programmierten autonomen Fahren verändert sich der Fokus vom Programmierer und den Programmparametern (Stichwort „Ethisches Coden“⁵⁹) hin zu den Zielen, zur Trainingsmethode und den Lerninputdaten. Es müssen Regeln für die Zielgenerierung, die Trainer, aber auch für die zugrundeliegenden Trainingsdaten geschaffen werden (zB Transparenz oder Standarddaten). Die Nutzung von Lerninputdaten präformiert das spätere Fahrverhalten. Während des Lernvorgangs müssen deshalb umfangreiche Verkehrssituationen abgebildet werden. Dadurch werden auch indirekt Werthaltungen in den Lernprozess aufgenommen. Gibt es dazu einen gesellschaftlich gültigen Wertekatalog? Können bzw dürfen Hersteller ihr eigenes Werthaltungsmodell (zB besonders dynamisches oder besonders verkehrssicheres Fahrverhalten) implementieren?

Mit diesen und anderen verkehrstechnischen, gesellschaftlichen und regulatorischen Fragen sollte sich die Gesellschaft und die Politik beschäftigen und nicht erst dann, wenn selbstlernende Fahrzeuge Straßen „bevölkern“ und von diesen nicht mehr wegzudenken sind.⁶⁰)

⁵⁹) Siehe idZ *I. Eisenberger* in diesem Band.

⁶⁰) In diesem Sinne schon *I. Eisenberger/Gruber/Huber/Lachmayer* (FN 7) 383.