

1 Einleitung

Seit dem Beginn des 20. Jahrhunderts hat die Mobilität durch Straßenfahrzeuge einen Aufschwung genommen, der bis heute anhält. In Deutschland waren im Jahr 2020 über 48 Millionen PKWs zugelassen [1]. Bedingt durch hohe Verkehrsdichte, komplexe Verkehrssituationen und menschliches Versagen wurden in diesem Jahr laut statistischem Bundesamt mehr als 2,2 Mio. Verkehrsunfälle registriert, davon ca. 311 000 mit Personenschäden, ausgelöst durch Fahrerfehlverhalten [1].

Weltweit werden bei der Fahrzeugentwicklung große Anstrengungen unternommen, um die Zahl dieser Verkehrsunfälle erheblich zu senken. Besonders im Fokus stehen hierbei neue Technologien wie Kollisionswarnsysteme, Fahrerassistenzsysteme oder autonome Fahrzeuge, für die die Erwartung besteht, dass sie im Gegensatz zum menschlichen Versagen völlig fehlerfrei agieren. Eine der Grundlagen zur Erreichung dieses „Null-Fehler-Ziels“ ist die sichere Erkennung von Gefahrensituationen unter der Vermeidung von Fehlerkennungen.

In diesem Beitrag wird ein neues Konzept vorgestellt, welches eine umfassende Sicherheitsbewertung von Fahrsituationen ermöglicht und sowohl zur Absicherung neuer Fahrzeugfunktionen in der Entwicklungsphase als auch direkt in intelligenten Fahrzeugsystemen eingesetzt werden kann. Das Konzept basiert auf stochastischen Modellen der Zusammenhänge zwischen Bewegungsdaten von Fahrzeugen und der Erzeugung von noch fehlendem Wissen unbekannter Zusammenhänge durch eine Methode der künstlichen Intelligenz. Durch die Verbindung dieser beiden Bausteine entsteht ein Gesamtmodell, welches auch komplexe Zusammenhänge über die Sicherheit von Fahrsituationen widerspiegelt.

In dem gemeinsamen Forschungsprojekt „MaxEnt“ der FernUniversität in Hagen und der Hochschule Esslingen wurde dieses Konzept im Rahmen einer Dissertation entwickelt, ein Workframe mit allen zur Realisierung erforderlichen Modulen entworfen und anhand von Fahrzeugbewegungsdaten erprobt. Der vorliegende Beitrag gibt nach einer Einführung in die Grundlagen der künstlichen Intelligenz und in die Grundlagen der Sicherheitsbewertung einen Überblick über das Konzept des Forschungsprojekts „MaxEnt“ sowie dessen Realisierung und Ergebnisse bei der Anwendung zur Sicherheitsbewertung von Fahrsituationen.

2 Wie Computer lernen und entscheiden

Wieder mal sind wir auf der Überholspur der Autobahn ziemlich flott unterwegs. Aber 100 m vor uns fährt auf demselben Fahrstreifen ein weiterer Verkehrsteilnehmer. Warum eigentlich führt dieses alltägliche Szenario fast nie zu einem Unfall?

Diesen glücklichen Umstand verdanken wir der menschlichen Intelligenz, die zur Bewältigung dieser Situation aber nur einen Teil ihrer vielen Fähigkeiten einsetzen muss. Deutlich wird dies, wenn wir unsere Verkehrssituation in einzelne Phasen zerlegen: Ihr Ablauf wird durch einen Reiz, dem Auftauchen eines anderen Verkehrsteilnehmers auf unserem Fahrstreifen ausgelöst. Die Einordnung und Bewertung der Reiz-Wahrnehmung erledigt das menschliche Gehirn aus gelerntem Wissen z.B. aus der Fahrschulzeit oder persönlichen Erfahrungen aus unserer Verkehrspraxis. Ist die Kritikalität der Situation eingeordnet, so wählen wir, wiederum auf der Basis unseres Wissens aus dem Baukasten der verfügbaren Handlungsoptionen „vom Gas gehen“, „bremsen“, „Spur wechseln“ eine Maßnahme aus und setzen diese unverzüglich um. Dank unseres Lern- und Erinnerungsvermögens müssen wir uns dabei nicht explizit mit der Frage „wie bremst man ein Auto?“ beschäftigen. Unser kleines Beispiel zeigt, wie viel menschliche Intelligenz in Form von Wahrnehmung, Erkennung, Bewertung, Erinnerung, Entscheidung und Handlung in der Bewältigung scheinbar einfacher Situationen steckt.

Leider geht der beschriebene Verkehrskonflikt nicht in 100% aller Fälle harmlos aus und sehr häufig liegt dies am sogenannten menschlichen Versagen in Form von Fehleinschätzung, Fehlreaktion oder Unaufmerksamkeit. Weltweit beschäftigt sich daher eine große Forscher-Community mit der Frage, wie Computer zur




Abbildung 1: Gliederung der Verfahren des maschinellen Lernens

Vermeidung derartiger Unfälle beitragen können. Der am weitesten verbreitete Lösungsansatz versucht die menschliche Intelligenz durch Algorithmen (Rechenvorschriften) in Computern nachzubilden (künstliche Intelligenz KI), wobei der Wissenserwerb durch maschinelles Lernen als Teilgebiet der KI eine zentrale Rolle spielt. Somit stellt sich die Frage „Wie lernen Computer?“, welche im Folgenden beantwortet werden soll.

Eine erste Gliederung der Verfahren des maschinellen Lernens, wie in Abbildung 1 dargestellt zeigt deutlich die Handschrift menschlichen Lernens.

Alle drei dargestellten Varianten des Lernens sind uns wohlbekannt, aber ihre Übertragung auf die künstliche Intelligenz bedarf ihrer Interpretation für die Welt der Computer.

Das Lernen mit Lehrer auch überwachtes Lernen oder Supervised Learning verwendet einen Satz von Trainingsdaten, um einen Rechneralgorithmus so zu trainieren, dass dieser die Merkmale oder Eigenschaften dieser Daten korrekt beschreibt. Dabei enthalten die Trainingsdaten nicht nur die Merkmale der betrachteten Objekte, sondern auch deren Klassifizierung. Soll der Algorithmus beispielsweise Kartoffeln nach Handelsklassen sortieren, so legt man ihm zu jeder „Trainingskartoffel“ neben deren Gewicht und Größe auch als Klassifizierungsergebnis die Handelsklasse vor, die zuvor von einem Fachmann festgestellt wurde. Möchte man hingegen kritische Fahr Situationen erkennen, so zeigt man dem Algorithmus vorab derartige Fahr Situationen einschließlich ihrer Bewertung durch Experten. Als prägendes Merkmal des Lernens mit Lehrer enthält somit jeder Trainingsdatensatz das gewünschte Klassifizierungsergebnis. Verbreitete Verfahren des Lernens mit Lehrer sind beispielsweise Entscheidungsbäume, Support Vector Machines, künstliche neuronale Netze oder Bayes-Klassifizierer. An späterer Stelle dieses Kapitels wird exemplarisch maschinelles Lernen anhand der Funktionsweise und des Lernvorgangs künstlicher neuronaler Netze beschrieben.

Das Lernen ohne Lehrer auch unüberwachtes Lernen oder Unsupervised Learning beschreibt die Fähigkeit von Menschen oder Maschinen Muster oder Zusammenhänge in Informationen / Daten zu erkennen, ohne dass diese von einem Experten oder Lehrer vorgegeben wurden. Dadurch sind die Anzahl und Art der Kategorien, in die die Daten einsortiert werden und die Kriterien, nach denen sortiert wird, nicht vorgegeben, sondern werden erst im Zuge des Lernprozesses erzeugt. Im Gegensatz zu unserem vorherigen Beispiel einer Kartoffel-Sortiermaschine, bei der sowohl die Kategorien in Form von Handelsklassen als auch die Unterscheidungskriterien wie Größe oder Farbe vorgegeben waren, liegen diese Informationen beim Lernen ohne Lehrer nicht vor. Hat ein Internetanbieter sehr viele Kundendaten gesammelt, so kann unüberwachtes Lernen nach noch nicht bekannten Mustern in den Daten suchen und diese nach den ermittelten Mustern kategorisieren. Das wohl bekannteste Verfahren des Lernens ohne Lehrer ist das hier beschriebene Clustering, welches nach Gemeinsamkeiten in den Lerndatensätzen sucht. Eine andere Strategie verfolgt die Dimensionsreduzierung, welche aus den Daten nur diejenigen Variablen auswählt, welche auch bei der späteren Klassifizierung anderer Daten relevant sind.

Das Lernen durch Belohnung, auch Lernen durch Verstärkung oder Reinforcement Learning erfolgt ebenfalls ohne Lehrer oder Experten. Der Wissenserwerb geschieht durch Versuch und Erfolg oder Misserfolg. Der Lernalgorithmus führt eine Aktion durch und bewertet das Ergebnis dieser Aktion, wobei positive Ergebnisse als Belohnung und negative Ergebnisse als Strafe betrachtet werden. Daher müssen Kriterien für Belohnung und Strafe festgelegt sein. Der Algorithmus lernt (verstärkt) Aktionen, welche zu einer Belohnung führen und verwirft diejenigen, die bestraft wurden. Die Routensuche eines Roboters in einem ihm unbekanntem Umfeld wird beispielsweise dann belohnt, wenn er sich durch eine Aktion einem gewünschten Endpunkt nähert. Der Lernaufwand vor einer Klassenarbeit wird durch die Benotung belohnt oder bestraft und daraus

Lernmethoden, die zur Belohnung führten (hoffentlich) gelernt. Verbreitete Verfahren des Lernens durch Belohnung sind das Q-Learning oder die Monte-Carlo-Methoden.

Allen drei Methoden ist gemeinsam, dass aus Stichproben, Versuchen oder Beispieldaten allgemeingültiges Wissen erzeugt wird, das auf eine ganze Klasse von Daten anwendbar ist. Die Suche nach Zusammenhängen in den Daten wird auch als Data Mining bezeichnet, die Übertragung einzelner Informationen auf eine ganze Klasse als Generalisierung.

Die Verfahren des maschinellen Lernens sind häufig komplexer Natur und erfordern eine intensive Beschäftigung mit ihren Strategien und Algorithmen. Um einen ersten Einblick zu vermitteln, werden im Folgenden der Aufbau und die Funktionsweise künstlicher neuronaler Netze (Artificial Neural Networks ANNs) als Beispiel für die Klasse maschineller Lernverfahren erklärt. ANNs wurden deshalb als Beispiel ausgewählt, da sie weit verbreitet sind und im Sprachgebrauch häufig mit künstlicher Intelligenz gleichgesetzt werden.

Das menschliche Gehirn besteht aus einem Netzwerk von Milliarden Nervenzellen (Neuronen), welche durch Synapsen (Kontaktstellen zwischen den Neuronen) miteinander verbunden sind. Künstliche neuronale Netze sind der Versuch, diese Struktur in Computern nachzubilden. Man kann sich die Anordnung der Neuronen als eine Reihe von Schichten vorstellen, wobei die Neuronen einer Schicht häufig nur mit denjenigen der direkten darüber- oder darunterliegenden Schicht über Synapsen verbunden sind.




Abbildung 2: Links: Modell eines einfachen neuronalen Netzes. Rechts: Anwendungsbeispiel zur Bewertung einer Verkehrssituation.

Abbildung 2 links zeigt das Modell eines einfachen neuronalen Netzes mit seiner Eingabeschicht (Input Layer), nur einer Zwischenschicht (verborgene Schicht, Hidden Layer) und seiner Ausgabeschicht (Output Layer). In der Eingabeschicht werden die zu analysierenden Informationen eingegeben, in Zwischenschichten erfolgen die Berechnungen und die Ausgabeschicht stellt Ergebnisse zur Verfügung. Reale künstliche neuronale Netze können über mehrere tausend Zwischenschichten verfügen, man spricht dann auch von Deep Learning. Die Anzahl der Zwischenschichten sowie die Anzahl der darin enthaltenen Neuronen bestimmen als sogenannte Hyperparameter die Fähigkeiten eines Netzes, welches durch den Lernvorgang an Trainingsdaten angepasst wird.

In Abbildung 2 rechts ist zu sehen, dass jeder Verbindung zwischen zwei Neuronen ein Gewicht w zugeordnet ist, mit dem der Ausgangswert eines Neurons multipliziert als Eingangsgröße an das verbundene Neuron weitergegeben wird. Dort werden die gewichteten Werte aller Neuronen aufsummiert und durch eine Aktivierungsfunktion bewertet und bilden so den aktuellen Zustand dieses Neurons. Dieser Prozess zieht sich über alle Neuronen in allen Schichten hin bis zu den Ausgabeneuronen, welche durch ihre Zustände (Werte) das Ergebnis repräsentieren. In der Abbildung ist ein einfaches neuronales Netz dargestellt, welches Verkehrskonflikte wie in eingangs beschriebener Situation auf der Autobahn bewertet. Dem Netz wird die Geschwindigkeit v_1 unseres Fahrzeugs, die Geschwindigkeit v_2 unseres Vorderfahrzeugs und der Abstand d beider Fahrzeuge zur Verfügung gestellt. Das erforderliche Wissen zur Beurteilung der Situation steckt in den zuvor gelernten Gewichten w . Als Ergebnis stellt das Netz in zwei Ausgangsneuronen beispielsweise die Wahrscheinlichkeiten „Kritische Situation: 25%“ und „Unkritische Situation: 75%“ bereit.

Da das spezifische Wissen eines Netzes in den Gewichten w steckt, stellt sich die Frage, wie diese Gewichte gelernt werden können. Eine grundlegende Antwort wurde bereits gegeben, dem Netz werden Lerndaten einschließlich der Einschätzung wie kritisch die Fahrsituation jedes Trainingsdatensatzes ist vorgelegt. Somit werden in einem Lernprozess mit Lehrer die Gewichte w über alle Trainingsdatensätze hinweg solange verändert, bis die Antwort des Netzes möglichst gut mit der jeweiligen Einschätzung des Lehrers übereinstimmt. Die Umsetzung dieser Idee in Rechenalgorithmen kann beispielsweise durch sogenannte Backpropagation [2] erfolgen. Dieser Begriff wird durch die Vorgehensweise geprägt, das Netz rückwärts von der Ausgabeschicht hin zur Eingabeschicht zu durchlaufen.

Zunächst werden die Eingangsdaten eines Trainingsdatensatzes in das Netz eingespeist, dessen Antwort wird von der Vorgabe des Lehrers subtrahiert und so eine Fehlerfunktion ermittelt. Nun wird das Netz von der Ausgabe rückwärts in Richtung Eingabeschicht durchlaufen und dabei die Gewichtungen so verändert, dass die Fehlerfunktion ein Minimum annimmt. Diese Schleife wird mehrfach über alle Trainingsdatensätze durchlaufen, solange bis sich das ermittelte Minimum des Fehlers nicht mehr ändert. Das Wissen, welches aus den Trainingsdaten gewonnen wurde, muss in einem weiteren Schritt mit Testdatensätzen, die nicht zum Lernen verwendet wurden, bestätigt werden. Am Ende eines derartigen Prozesses sind beispielsweise alle Gewichte w aus Abbildung 2 rechts bekannt und das neuronale Netz kann zu jedem Zeitpunkt ermitteln, wie kritisch die derzeitige Fahrsituation ist.

Zur Vertiefung der Wissensgebiete Künstliche Intelligenz und Maschinelles Lernen sei auf Fachliteratur hingewiesen, wie z.B. [3], [4] oder [2]. In Kapitel 5 wird ein weiteres KI-Verfahren vorgestellt, welches eine ganz andere Strategie, als die Modellierung menschlichen Denkens verfolgt.

3 Konflikt-Techniken vermeiden Unfälle

Im vorherigen Kapitel wurde gezeigt, wie Computer lernen Entscheidungen zu treffen. Auch in unserem kleinen Beispiel von der Autobahn entschied ein Algorithmus, ob die Situation als kritisch oder unkritisch einzuschätzen ist. Allerdings basierte diese Entscheidung auf Wissen, welches durch einen Lehrer / Experten vorgegeben wurde. Woher aber weiß der Lehrer, wann es gefährlich wird?

Forscher und Entwickler beschäftigen sich intensiv mit der Frage, wie Gefahrensituationen frühzeitig erkannt und somit Unfälle vermieden werden können. Insbesondere bei der Entwicklung von Fahrerassistenzsystemen und autonomen Fahrzeugen hat dieser Aspekt aller höchste Relevanz.

Ein etablierter Lösungsansatz ist die sogenannte Traffic Conflict Technique TCT [5], bei der Sicherheitsmaße (Metriken) zur Beurteilung von Fahrsituationen verwendet werden. Die Metriken der TCT beschreiben Fahrsituationen oder auch Verkehrskonflikte in Form von Algorithmen und ermöglichen dadurch deren Beurteilung durch Computer. Als Verkehrskonflikte werden Situationen bezeichnet, die als kritisch anzusehen sind, aber in der Regel zu keiner Kollision (Unfall) führen.

Untersuchungen aus der Unfallforschung zeigen einen statistischen Zusammenhang zwischen der Anzahl der Verkehrskonflikte und der Anzahl der Unfälle. Damit liegt in der Erkennung und Beurteilung aber auch der Reduzierung von Konflikten ein Schlüssel zur Vermeidung von Verkehrsunfällen. In den folgenden Abschnitten werden drei der wichtigsten Metriken der TCT vorgestellt, stellvertretend für eine Vielzahl an publizierten Sicherheitsmaßen [6]. Diese drei häufig genutzten Metriken sind unter folgenden Namen bekannt:

- Time to Collision TTC.
- Time Headway THW.
- Post Encroachment Time PET.

Im Jahr 1972 stellte J. C. Hayward [7] mit der Time to Collision TCT eine Metrik vor, die auch noch heute eines der Kernelemente bei der Beurteilung von Verkehrskonflikten darstellt. Die TTC ist ein Sicherheitsmaß,




Abbildung 3: Fahrzeugfolge-Szenario

welches in Situationen angewendet wird, in denen zwei Fahrzeuge, so wie in unserem Eingangsbeispiel hintereinander auf demselben Fahrstreifen fahren und sich ihr Abstand verringert. Man spricht dann von einem Fahrzeugfolge-Szenario, siehe auch Abbildung 3. Wenn beide Fahrzeuge ihre momentane Geschwindigkeit beibehalten, so stellt bei einem aktuellen Abstand d beider Fahrzeuge die TTC diejenige Zeit dar, innerhalb deren es zu einer Kollision kommen würde.

Die Rechenvorschrift zur Bestimmung der TTC lautet

$$TTC[s] = \frac{d [m]}{(v_F - v_V) [m/s]} \quad (1)$$

wobei v_F die Geschwindigkeit des Folgefahrzeugs, v_V die Geschwindigkeit des vorausfahrenden Fahrzeugs und d der Abstand beider Fahrzeuge darstellen. Bei der Auswertung der TTC nach Formel (1) sind drei Szenarien zu unterscheiden:

1. Das vorausfahrende Fahrzeug ist schneller als das Folgefahrzeug, also $v_F - v_V < 0$. Dann wäre eine Kollision ausgeschlossen, was durch einen negativen Wert der TTC signalisiert wird.
2. Beide Fahrzeuge fahren gleich schnell, also $v_F = v_V$. Dann wäre eine Kollision ebenfalls ausgeschlossen und die TTC geht gegen unendlich.
3. Der dritte, zweifellos interessanteste Fall tritt immer dann auf, wenn das Folgefahrzeug schneller fährt als sein Vorderfahrzeug, also $v_F - v_V > 0$. Dann würde im weiteren Verlauf der Abstand d abnehmen und es käme zu einer Kollision. Je kleiner die positiven Werte der TTC sind, umso kürzer ist die verbleibende Zeitspanne, um einen Unfall abzuwenden. Liegt die TTC im Bereich der typischen menschlichen Reaktionszeit ($< 1s$), so wird es fast immer kritisch.

Angenommen unser Fahrzeug verfügt über einen „TTC-Warner“, der sich bei kleinen TTCs meldet, wären wir dann gegen alle kritischen Fahrzeugfolge-Situationen gewappnet? Leider nein; ein sehr geringer Abstand zum Vorderfahrzeug bei gleicher Geschwindigkeit $v_F = v_V$ hätte eine unendlich hohe TTC zur Folge und unser Warngerät würde sich nicht melden. Für derartige Szenarien stellt die TCT eine andere Metrik zur Verfügung, die Time Headway THW [6]. Hinter der THW verbirgt sich der wohlbekannte Stoßstangenabstand zweier Fahrzeuge, welcher auf die Geschwindigkeit des Folgefahrzeugs bezogen wird. Somit beschreibt die THW diejenige Zeitspanne, ab der die hintere Stoßstange des Vorderfahrzeugs eine bestimmte Stelle verlässt, bis die vordere Stoßstange des Folgefahrzeugs diese Stelle erreicht. Die Formel der THW lautet

$$THW[s] = \frac{d [m]}{v_F [m/s]} \quad (2)$$

Wie bei der TTC stehen auch bei der THW kleinere Werte für kritischere Situationen. In der Fahrschule haben wir die Regel „halber Tachoabstand“ gelernt, welche letztendlich dasselbe ist, wie eine THW von 1,8 s. Dieser Wert entspricht in etwa der doppelten menschlichen Reaktionszeit. Unterhalb einer THW von 0,9 s sieht dann der Bußgeldkatalog in Deutschland Sanktionen vor.

Die Fahrfolge zweier Fahrzeuge stellt nur einen Teil der häufigen Verkehrsszenarien dar und die TCT benötigt beispielsweise für Situationen an Kreuzungen andere Sicherheitsmaße. Eine dieser Metriken, die Post




Abbildung 4: Querkonflikt zweier Fahrzeuge

Encroachment Time PET [6] beschreibt die Kritikalität sogenannter Querkonflikte an Kreuzungen oder beim Spurwechsel durch ein Konzept, welches ähnlich zum Ansatz der THW aufgebaut ist: Die PET repräsentiert die Zeitspanne, ab der ein erstes Fahrzeug F1 eine bestimmte Stelle verlässt, bis ein zweites Fahrzeug F2 diese Position erreicht¹. Dieser Ort wird als Konfliktpunkt oder Conflict Point CP bezeichnet. Abbildung 4 zeigt schematisch eine derartige Situation.

Die Rechenvorschrift der PET in Formel (3.3) hat dieselbe Struktur wie die Formel für die THW in Formel (3), und beschreibt vereinfachend eine Situation gemäß Abbildung 4, in der sich beide Fahrzeuge in einem rechten Winkel zueinander bewegen.

$$PET[s] = \frac{d [m]}{v_{F2} [m/s]} \quad (3)$$

Kleine Werte der Post Encroachment Time stehen für kritische Situationen und $PET = 0s$ ist die mathematische Beschreibung einer Kollision da sich in diesem Fall beide Fahrzeuge zum selben Zeitpunkt an derselben Stelle aufhalten.

Alle drei hier beschriebenen Metriken gehen davon aus, dass sich die Geschwindigkeiten beider Fahrzeuge und deren Fahrtrichtungen im weiteren Verlauf der Verkehrssituation nicht ändern. Da diese Annahmen häufig nicht zutreffen, wurden die Metriken weiterentwickelt, sodass sie beispielsweise von konstanten Beschleunigungen anstatt von konstanten Geschwindigkeiten ausgehen. Für jede Metrik muss ein Schwellenwert festgelegt werden, welcher zur Unterscheidung zwischen unkritischen und kritischen Situationen dient und somit das Ergebnis der Situationsbewertung maßgeblich beeinflusst.

Ein ganz anderer Ansatz zur besseren Beschreibung von Verkehrskonflikten ist die stochastische Modellierung, bei der Situationen durch Wahrscheinlichkeiten physikalischer Größen wie Zeiten oder Abständen anstelle von absoluten Werten beschrieben werden. So ist beispielsweise die Reaktionszeit aller Autofahrer keinesfalls eine einzige Größe, sondern die Reaktionszeiten der Menschen sind innerhalb eines bestimmten Zeitbereichs unterschiedlich und lassen sich durch ihre Wahrscheinlichkeitsverteilung beschreiben. In den folgenden Kapiteln wird auf die stochastische Modellierung von Verkehrskonflikten näher eingegangen.

Zurück zu unserer Beispielsituation auf der Autobahn. Da wir auf demselben Fahrstreifen schneller unterwegs sind als unser Vorderfahrzeug, bietet sich die TTC als Metrik zur Bewertung an. Wenn unsere Geschwindigkeit 150 km/h und die des Vorderfahrzeugs 100 km/h beträgt, dann würde es bei einem derzeitigen Abstand von 20 m nach ungefähr 1.44 s, also $TTC = 1.44s$ zu einer Kollision kommen. In Studien wird häufig ein Schwellenwert von 1.5 s zur Unterscheidung kritisch / unkritisch genannt. Bei einer TTC von 1.44 s wäre damit die aktuelle Situation als kritisch einzustufen und ein Kollisionswarner würde sich melden. Verfügt ein Fahrzeug über einen intelligenten Assistenten zur Kollisionsvermeidung (Collision Avoidance System CAS), so würde dieser die Bremse betätigen.

Mit der Weiterentwicklung intelligenter Assistenzsysteme hin zu voll autonomen Fahrzeugen steigen die Anforderungen an die Erkennung und Bewertung von Verkehrskonflikten und somit an die Traffic Conflict

¹Bewegen sich zwei Fahrzeuge nicht in einem rechten Winkel zueinander, so werden diejenigen Stellen der beiden Karosserien betrachtet, welche den geringsten Abstand haben.

Technique TCT weiter an. Andererseits stehen mit einer wachsenden Anzahl an Sensoren und der Kommunikation zwischen Fahrzeugen immer mehr Informationen zur Verfügung, um mit Methoden der künstlichen Intelligenz auch komplexe Verkehrssituationen mit höherer Sicherheit zu bewerten.

4 Maximale Entropie bewertet Fahrsicherheit

Um komplexe Zusammenhänge besser verstehen und berechnen zu können, bedient sich die Wissenschaft häufig sogenannter Modelle. Ein Modell ist ein mathematisches Abbild des Zusammenspiels verschiedener Größen und kann beispielsweise physikalischer, medizinischer, ökonomischer oder meteorologischer Art sein.

Grundsätzlich kann man zwischen deterministischen und stochastischen Modellen unterscheiden, wobei die deterministischen Modelle aus eindeutigen Regeln, wie „Immer, wenn man den Lichtschalter betätigt, geht das Licht an“ aufgebaut sind. Handelt es sich allerdings um einen älteren Lichtschalter, bei dem das Licht nur in drei von vier Fällen tatsächlich angeht, so lässt sich dieses Verhalten viel präziser in einem stochastischen Modell beschreiben: „Wenn der Schalter betätigt wird, so geht mit 75%iger Wahrscheinlichkeit das Licht an“. Im vorangegangenen Kapitel wurde bereits erwähnt, dass auch viele Größen der Traffic Conflict Technique TCT, wie z. B. menschliche Reaktionszeiten von stochastischer Natur sind und sich daher besser über Wahrscheinlichkeiten beschreiben lassen.

Nach einer kurzen Einführung einiger Begriffe der Wahrscheinlichkeitsrechnung und der Definition des Informationsgehalts eines Ereignisses wird in diesem Kapitel eine Methode vorgestellt, wie umfangreiche stochastische Modelle aufgestellt werden können, auch wenn nur ein Teil aller Zusammenhänge bekannt ist. Anschließend wird gezeigt, wie diese Methode zur Sicherheitsbewertung von Fahrsituationen in der TCT angewendet werden kann.

Wenn jedem Zustand, den eine Variable annehmen kann, eine Wahrscheinlichkeit zugeordnet ist, dann spricht man von einer Zufallsvariablen und die Zustände selbst nennt man Elementarereignisse. Ein Lichtschalter besitzt zwei mögliche Zustände oder Elementarereignisse ein Würfel derer sechs. Beim idealen Würfel tritt jede mögliche Zahl also jedes Elementarereignis mit derselben Wahrscheinlichkeit von einem Sechstel auf und die Summe aller Wahrscheinlichkeiten beträgt Eins. Die Aussage, dass die Summe aller Wahrscheinlichkeiten gleich Eins ist, gilt allgemein und heißt Normierungsbedingung.

Die Gesamtheit der Wahrscheinlichkeiten aller Elementarereignisse nennt man die Wahrscheinlichkeitsverteilung einer Zufallsvariablen. Tabelle 1 zeigt, dass bei einem fairen Würfel die Wahrscheinlichkeiten gleich verteilt sind, wohingegen dieses bei einem manipulierten Würfel keinesfalls zutrifft. Man will ja gezielt mehr Sechsen würfeln also soll dieses Elementarereignis mit einer höheren Wahrscheinlichkeit als die anderen auftreten.

	$p(1)$	$p(2)$	$p(3)$	$p(4)$	$p(5)$	$p(6)$	Summe
Fairer Würfel	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	1.0
Manipulierter Würfel	$\frac{1}{12}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{3}{12}$	1.0

Tab. 1: Wahrscheinlichkeitsverteilungen eines fairen und eines manipulierten Würfels. Hierbei steht beispielsweise $p(4)$ für die Wahrscheinlichkeit eine Vier zu würfeln

Häufig interessiert nicht nur die absolute Wahrscheinlichkeit eines Ereignisses, vielmehr will man wissen wie wahrscheinlich dieses Ereignis ist, wenn es an weitere Bedingungen geknüpft ist. Dann spricht man von bedingter Wahrscheinlichkeit.

Angenommen eine Verkehrserhebung ergibt, dass in der Gesamtmenge aller Fahrradfahrer 48% weiblich sind und dass unter allen Radfahrern der Anteil von Frauen mit E-Bike 12% beträgt. Dann berechnet sich die bedingte Wahrscheinlichkeit, dass eine Person ein E-Bike fährt unter der Bedingung, dass es sich um eine Radfahrerin handelt, mit

$$p(e|w) = \frac{p(e \cap w)}{p(w)} = \frac{12}{48} = 0.25 \quad (4)$$

wobei w für weibliche Radfahrer, e für e-Bike-Fahrer/innen stehen und der senkrechte Strich der Operator der bedingten Wahrscheinlichkeit ist. $p(e \cap w)$ ist die Wahrscheinlichkeit, dass eine Person e-Bike fährt und weiblich ist. Die bedingte Wahrscheinlichkeit $p(e|w)$ ergibt sich also, wenn man den Anteil der Frauen mit E-Bike nur auf den Frauenanteil unter allen Radfahrern bezieht.

Wahrscheinlichkeitsverteilungen und bedingte Wahrscheinlichkeiten sind mächtige Werkzeuge, um Zusammenhänge stochastisch zu modellieren. Allerdings liegt häufig nicht das Wissen über die Wahrscheinlichkeiten aller Zusammenhänge vor. Wenn ein Modell aus sehr vielen Zufallsvariablen besteht und jede dieser Zufallsvariablen mehrere Elementarereignisse besitzt, so beinhaltet die Wahrscheinlichkeitsverteilung so viele Werte, dass diese nicht mehr experimentell oder durch Schätzung ermittelt werden können. Betrachtet man z.B. fünf Würfel, von denen jeder individuell manipuliert wurde, also jeder eine andere Wahrscheinlichkeitsverteilung besitzt, so können beim Würfeln insgesamt $6 \cdot 6 \cdot 6 \cdot 6 \cdot 6 = 7776$ unterschiedliche Kombinationen auftreten, denen jeweils eine individuelle Auftretenswahrscheinlichkeit zugeordnet ist. Allgemein gilt, dass die Anzahl der Zufallsvariablen die Dimension der Wertetabelle aller Wahrscheinlichkeiten bestimmt. Man kann sich die Verteilung einer einzigen Zufallsvariablen in einer Zeile oder Spalte, die zweier Variablen in einer Matrix und die dreier Variablen in einem Quader vorstellen. Im Fall der fünf manipulierten Würfel spannt die Wahrscheinlichkeitsverteilung einen schwerer vorstellbaren fünfdimensionalen Raum auf. Diese Überlegungen zeigen, dass das Füllen eines derartigen hochdimensionalen Gebildes mit Zahlenwerten eine schwierige und umfangreiche Aufgabe darstellt. Im Folgenden wird eine Strategie vorgestellt, welche uns diese Arbeit vollständig abnimmt.

Um diese Strategie verständlich zu machen, sollen zunächst einige Begriffe aus der Informationstheorie eingeführt werden. Das zentrale Element, auf der die Informationstheorie und auch diese Methode aufbauen ist der Informationsgehalt einer Nachricht oder eines Zufallsereignisses.

Der amerikanische Mathematiker Claude E. Shannon stand Mitte des 20. Jahrhunderts vor der Fragestellung, wie Nachrichten / Informationen möglichst effizient übertragen werden können. Hierzu schlägt Shannon in seinem Standardwerk „A Mathematical Theory of Communication“ [8] vor, die unterschiedlichen Zeichen eines Zeichenvorrats X mit einer unterschiedlichen Anzahl von Bits zu kodieren², wobei diese Anzahl dem sogenannten Informationsgehalt eines Zeichens entspricht. Der Informationsgehalt $I(x_j)$ eines Zeichens x_j , welches eine Auftretenswahrscheinlichkeit $p(x_j)$ besitzt, ist formal beschrieben durch

$$I(x_j) = \frac{1}{\log_2(p(x_j))} \quad (5)$$

wobei \log_2 den Logarithmus zur Basis 2 darstellt. Durch diese Basis 2 ergibt sich der Informationsgehalt in der Einheit Bits.

Formel (5) besagt, dass der Informationsgehalt eines Zeichens steigt, wenn dessen Auftretenswahrscheinlichkeit sinkt. Man kann sich diesen Zusammenhang leicht vorstellen, wenn man Information als das Beseitigen von Unsicherheit interpretiert. Die Information „am Nordpol ist es kalt“ beseitigt wenig Unsicherheit und besitzt daher einen geringen Informationsgehalt, wohingegen ein Wintereinbruch in der Sahara sehr unwahrscheinlich ist und deshalb einen hohen Informationsgehalt hat.

Wie aber half diese Erkenntnis Shannon bei der effizienten Übertragung von Informationen? Stellen wir uns vor, dass ein Computer ermittelt, welcher Buchstabe des Alphabets wie oft in einem dicken Buch wie dem Brockhaus oder der Bibel vorkommt. Dann erhalten wir eine Wahrscheinlichkeitsverteilung über alle

²Schon im 19. Jahrhundert verwendete Samuel Morse in seinem Morse-Alphabet unterschiedliche Codelängen, allerdings noch nicht auf Basis einer formalen Definition des Informationsgehalts.

alphanumerischen Zeichen. Gemäß Formel (5) werden dann häufige Buchstaben, wie ein „E“ oder ein „N“ in weniger Bits codiert, wie z. B. ein „Y“ oder ein „Q“, woraus unmittelbar folgt, dass die Übertragung des Brockhaus mit dieser Codierung wesentlich effizienter ist als die Codierung aller Buchstaben mit gleichviel Bits. Während der Informationsgehalt $I(x_j)$ nur eine Aussage über ein einzelnes Zeichen eines Zeichenvorrats macht, ist die sogenannte Entropie $H(X)$ ein Maß für eine gesamte Wahrscheinlichkeitsverteilung. Sie ist als gewichtete Summe aller Informationsgehalte wie folgt definiert:

$$H(P(X)) = \sum_j \frac{p(x_j)}{\log_2(p(x_j))} = - \sum_j p(x_j) \cdot \log_2(p(x_j)) \quad (6)$$

Die Formel (6) ordnet jeder Wahrscheinlichkeitsverteilung $P(X)$ eine Entropie $H(P(X))$ zu, wobei stets die sogenannte Normierungsbedingung (die Summe der Wahrscheinlichkeiten aller Elementarereignisse beträgt Eins) gilt. Die Entropie beschreibt die Menge an Unsicherheit, die in einer Wahrscheinlichkeitsverteilung $P(X)$ steckt. Je größer die Unsicherheit über das Eintreten der Elementarereignisse ist, desto größer ist auch deren Entropie $H(P(X))$. Die Wahrscheinlichkeitsverteilung eines fairen Würfels besitzt maximale Entropie, da der Ausgang eines Wurfes völlig offen ist. In Tabelle 2 sieht man die Entropien eines fairen und eines manipulierten sowie eines „Sechser“-Würfels im Vergleich. Der manipulierte Würfel hat eine niedrigere Entropie als ein fairer Würfel, da das Würfeln einer Sechs weniger überraschend ist. Ein Würfel, der immer nur Sechsen würfelt besitzt die niedrigste Entropie von Null, da es ja über den Ausgang eines Wurfs keinerlei Unsicherheit gibt

	$p(1)$	$p(2)$	$p(3)$	$p(4)$	$p(5)$	$p(6)$	Entropie
Fairer Würfel	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	2.585
Manipulierter Würfel	$\frac{1}{12}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{3}{12}$	2.522
„Sechser“-Würfel	0	0	0	0	0	1	0.0


Tab. 2: *Wahrscheinlichkeitsverteilungen und Entropien eines fairen Würfels, eines manipulierten Würfels und eines reinen „Sechser“-Würfels*

Sind Zusammenhänge zwischen Zufallsvariablen nur teilweise bekannt und in deren Wahrscheinlichkeitsverteilung fehlen somit Wahrscheinlichkeitswerte, so spricht man von Wissenslücken oder Information Gaps [9] und es stellt sich die Frage, wie diese Lücken gefüllt werden können. Man könnte willkürliche Annahmen treffen, wie z. B. „die Wahrscheinlichkeit aller unbekannteren Zusammenhänge ist gleich groß“. Allerdings fehlt in vielen Fällen selbst für eine derartige Annahme jeglicher Anhaltspunkt.

Einen ganz anderen Lösungsansatz entwickelte der amerikanische Mathematiker E. T. Jaynes [10] auf Basis des Informationsgehalts und der Entropie. Seine Idee lässt sich wie folgt beschreiben: Wenn in einer Wahrscheinlichkeitsverteilung Wissen fehlt und daher hinzugefügt werden muss, so soll dieses so wenig wie möglich vermeintlich sicheres Wissen enthalten. Dies bedeutet, dass die Wissenslücken einer Wahrscheinlichkeitsverteilung so aufgefüllt werden, dass diese eine maximale Unsicherheit und somit eine maximale Entropie besitzt. Dieses Konzept von Jaynes wird als die Methode der maximalen Entropie bezeichnet und fand bereits in zahlreichen KI-Systemen Anwendung. Die Methode der maximalen Entropie wählt somit unter all denjenigen Wahrscheinlichkeitsverteilungen, welche u. a. das vorhandene lückenhafte Wissen enthalten diejenige aus, welche die maximale Entropie besitzt, also die größtmögliche Unsicherheit enthält. In der ausgewählten Verteilung besitzt jedes Ereignis einen Wahrscheinlichkeitswert und somit sind die Wissenslücken durch die Strategie von Jaynes geschlossen. Seien $P(X)$ die Menge aller Wahrscheinlichkeitsverteilungen einer oder mehrerer Zufallsvariablen X , so wählt die Methode diejenige Verteilung $P^*(X)$ aus, für die gilt:

$$H_{max} = \operatorname{argmax}(H(P(X))) = H(P^*(X)) \quad (7)$$

wobei H_{max} das Maximum der Entropie darstellt und argmax die Verteilung mit der größten Entropie auswählt. Das Ergebnis dieser Berechnung ist eine Wahrscheinlichkeitsverteilung P^* , welche keine Wissenslücken mehr enthält und so ein vollständiges stochastisches Modell bildet.

Abbildung 5: Shannon-Funktion der Zufallsvariablen X

Die Maximierung der Entropie soll nun an einem einfachen Beispiel verdeutlicht werden. Gegeben sei eine Boolesche Zufallsvariable X mit zwei Elementarereignissen x_1 und x_2 . Über die Wahrscheinlichkeiten mit denen x_1 und x_2 auftreten ist leider nichts bekannt und es gilt somit nur die Normierungsregel, welche besagt, dass die Summe aller Wahrscheinlichkeiten gleich Eins ist, also $p(x_1) + p(x_2) = 1$ oder $p(x_2) = 1 - p(x_1)$. Die Entropie $H(P(X))$ dieser Verteilung berechnet sich nach

$$H(P(X)) = \frac{p(x_1)}{\log_2(p(x_1))} + \frac{1 - p(x_1)}{\log_2(1 - p(x_1))} \quad (8)$$

Ermittelt man die Entropie nach dieser Formel für alle Wahrscheinlichkeiten von x_1 zwischen 0 und 1, so entsteht das Diagramm in Abbildung 5. Man nennt diese Kurve auch die Shannon-Funktion.

Die Shannon-Funktion hat bei $p(x_1) = 0$ und bei $p(x_1) = 1$ den Wert Null, denn hier besteht keinerlei Unsicherheit über den Ausgang eines Experiments. Die maximale Entropie tritt bei $p(x_1) = 0.5$ auf, da hier beide Elementarereignisse x_1 und x_2 gleich wahrscheinlich sind und somit maximale Unsicherheit herrscht. Dieses Beispiel zeigt die grundsätzliche Vorgehensweise zur Berechnung der maximalen Entropie, auch wenn in diesem einfachen Fall das Ergebnis leicht vorhersehbar ist.

Deutlich komplexer wird die Situation, wenn maximale Entropie zur Bewertung der Sicherheit von Fahrsituationen eingesetzt wird. Sollen hierbei die Metriken TTC, THW und weitere Größen der Traffic Conflict Technique in einem stochastischen Modell verknüpft werden, welches eine Aussage über die Wahrscheinlichkeit einer kritischen Fahrsituation macht, so fehlt teilweise Wissen über Zusammenhänge zwischen den Metriken. Aufgrund der Vielzahl von Zufallsvariablen mit jeweils mehreren Elementarereignissen können die fehlenden Zusammenhänge nicht geschätzt werden, aber durch die Maximierung der Entropie kann eine vollständige Wahrscheinlichkeitsverteilung und somit ein vollständiges stochastisches Modell erzeugt werden. Im folgenden Kapitel werden das Konzept, der Prozess und die Toolkette zur Gewinnung und Verwendung dieses Modells beschrieben.