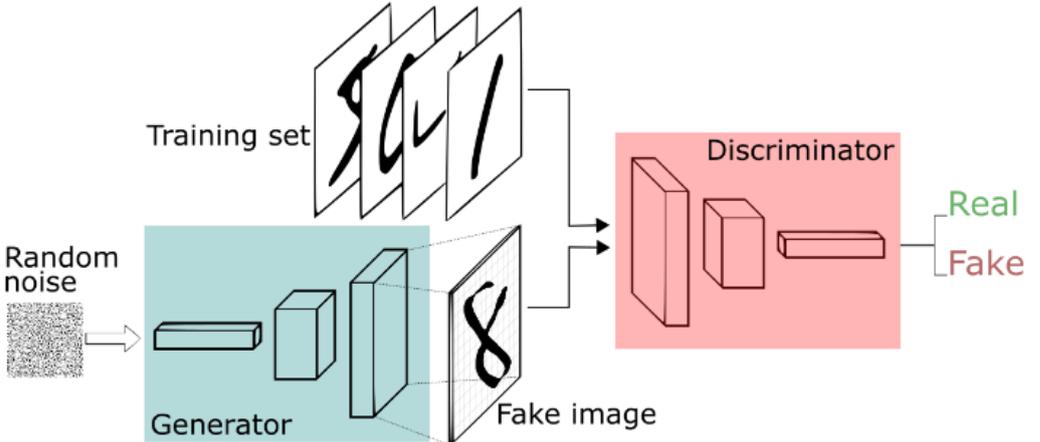


Bachelorarbeit	Analyse verschiedener Metriken zur datenbasierten Modellselektion
Hintergrund	<p>Typischerweise wird bei der Systemidentifikation der <i>quadratische</i> Prädiktionsfehler (Least-Squares-Methode, L_2-Norm) minimiert, wodurch sich die Modellparameter im ARX-Fall direkt berechnen lassen. Im Zuge einer vorangegangenen Bachelorarbeit wurde untersucht in welchen Fällen alternative Normen (L_1-Norm, L_∞-Norm) unter Umständen zu einem besseren Ergebnis führen.</p> <p>Im Falle einer Identifikation mit nichtlinearen Regressoren (z.B. Polynomen) spielt zudem eine Regressorselektion (Reduzierung des Modells auf die essentiellen Terme) eine wesentliche Rolle. Die Verwendung der alternativen Metriken soll nun auch für die Regressorselektion analysiert werden.</p>
Ziel	<p>Es gilt die Ergebnisse der vorangegangenen Arbeit anhand weiterer Simulationsstudien (sowie einer Literaturrecherche) abzusichern sowie die Anwendbarkeit verschiedener alternativer Normen auf die Regressorselektion (Modellselektion) zu untersuchen. Beispielsweise verwendet das bekannte Verfahren LASSO die L_1-Norm um irrelevante Modellparameter Null zu setzen. Der Einfluss verschiedener Normen soll auf andere Methoden ausgedehnt werden.</p> <div data-bbox="715 972 1145 1361" data-label="Image"> <p>Das Diagramm zeigt drei Einheitsformen in einem 2D-Koordinatensystem mit Achsenpfeilen. Oben links ist ein rosa schraffierter Kreis (L2-Norm). Oben rechts ist ein blaues schraffiertes Quadrat (L1-Norm). Unten ist ein blaues schraffiertes Achteck (L-infinity-Norm). Zwischen den Formen befinden sich grüne Pfeile, die den Text 'CIRCLES' bilden.</p> </div> <p>Einheitskreis in verschiedenen Metriken [http://mathwithbaddrawings.com]</p>
Optional	Die Tauglichkeit der Methoden soll anhand realer Daten (z.B. vom Motorprüfstand) getestet werden.
Besonderes	<p>Interesse am Themengebiet Identifikation sowie gute Programmierkenntnisse werden vorausgesetzt.</p> <p>Theorie 30%, Simulation 60%, Praxis 10%</p>
Betreuer	Florian Meier

Bachelorarbeit	Szenario-Extraktion über Matrixprofil
Hintergrund	<p>Das Matrixprofil (MP) ist ein leistungsstarkes Tool, um die doppelten Probleme der Anomalieerkennung und der Mustererkennung (oder "Motiv") zu lösen. MP ist robust, skalierbar und weitgehend parameterfrei.</p> <p>Die Grundlagen von MP sind einfach: Wenn ich einen Ausschnitt aus meinen Daten nehme und ihn über den Rest der Zeitreihe schiebe, was ist dann die resultierende Überlappung an jeder Position? Genauer gesagt, können wir den euklidische Distanz zwischen einer Teilsequenz und jedem möglichen Zeitreihensegment gleicher Länge auswerten und so die so genannten Teilsequenzen "Distance Profile" aufbauen. Wenn sich die Teilsequenz in den Daten wiederholt, gibt es mindestens eine Übereinstimmung und der Mindestabstand ist Null oder bei Vorhandensein von Rauschen nahe Null.</p> <p>Im Gegensatz dazu, wenn die Teilsequenz sehr einzigartig ist (z.B. wenn sie einen signifikanten Ausreißer enthält), ist die Übereinstimmung schlecht und alle Überlappungswerte sind hoch. Beachten Sie, dass die Art der Daten irrelevant ist: wir betrachten nur die Erhaltung von Mustern. Wir verschieben dann jeden möglichen Ausschnitt über die Zeitreihe und bauen eine Sammlung von Entfernungsprofilen auf. Indem wir den Mindestwert für jeden Zeitschritt über alle Streckenprofile hinweg festlegen, können wir den endgültigen MP bauen.</p> <p>Beide Enden des MP-Wertspektrums sind sinnvoll. Hohe Werte deuten auf ungewöhnliche Muster oder anomale Ereignisse hin; niedrige Werte hingegen heben wiederholbare Motive hervor und geben wertvolle Einblicke in Ihre Zeitreihe von Interesse.</p>

Ziel	<p>Ziel der Arbeit ist es, die Verkehrsdaten mit dem MP zu analysieren. Ein besonderes Interesse liegt darin, die "Ausreißer", d.h. die seltenen oder ungewöhnlichen Szenarien, herauszufinden.</p>
------	---

Optional	MP unter der Dynamic Time Warping (DTW) Distanz
Besonderes	<p>Der Student sollte sich für die Themen Automobilbereich und Datenanalyse interessieren.</p> <p>Datenanalyse 50%, Simulation 40%, Theorie 10%.</p>
Betreuer	Dr. Pavlo Tkachenko

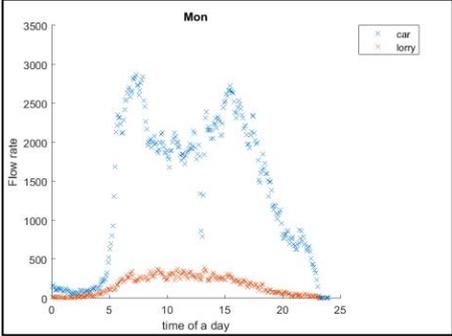
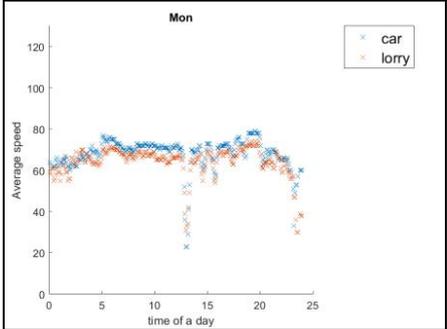
Bachelorarbeit	Stochastische Traffic-Generierung
Hintergrund	<p>Generative Adversarial Networks (GANs) sind eine Klasse von neuronalen Netzwerkarchitekturen, die mit dem Ziel entwickelt wurden, realistische Daten zu generieren. Der Ansatz beinhaltet das Training von zwei neuronalen Modellen mit Zielkonflikten, einem Generator (G) und einem Diskriminator (D), die sich gegenseitig zur Verbesserung zwingen. Der Generator versucht, Samples zu erzeugen, die echt aussehen, und der Diskriminator versucht, zwischen erzeugten Samples und realen Daten zu unterscheiden. Die Verwendung dieses Frameworks ermöglicht es, tiefe generative Modelle ohne teure Normierungskonstanten zu trainieren, und die Technik hat bewiesen, dass sie sehr realistische Datenproben erzeugt.</p>
Ziel	<p>In einer vorherigen Arbeit wurden GAN und zwei seiner Modifikationen (WGAN und WGAN-GP) entwickelt, um die Trajektorien und Geschwindigkeitsprofile von 1 und 2 Fahrzeugen zu generieren. In dieser Arbeit ist es das Ziel, den Ansatz auf mehr bewegte Objekte auszudehnen, um ein komplexes Verkehrsszenario zu generieren. Als möglicher Ansatz können die von GAN kommenden stochastischen Trajektorien als Input für ein klassisches (tiefes) NN dienen, das die restlichen Trajektorien an seinem Ausgang liefert.</p>  <p>Das Diagramm zeigt den Prozess eines GAN. Ein Generator (G) nimmt Random noise als Input und erzeugt ein Fake image (z.B. die Ziffer 8). Ein Training set (z.B. die Ziffern 5, 0, 4, 1) wird als Input für den Discriminator (D) verwendet. Der Discriminator unterscheidet zwischen Real (z.B. die Ziffer 8) und Fake (z.B. die Ziffer 8) Bildern.</p>
Optional	<p>Viele verschiedene Varianten von GAN und NN können zum Vergleich und zur Verbesserung der Ergebnisse verwendet werden.</p>
Besonderes	<p>Die Studierenden sollten sich für den Automobilbereich sowie für Datenanalyse und (tiefe) neuronale Netze interessieren.</p> <p>Theorie 20%, Simulation 50%, Datenanalyse 30%.</p>
Betreuer	<p>Dr. Pavlo Tkachenko</p>

Bachelorarbeit	Klassifizierung des longitudinalen Fahrkomforts
Hintergrund	<p>Menschen haben ein unterschiedliches Empfinden für Fahrkomfort. Was der Fahrer während der Fahrt als komfortabel empfindet, kann für den Beifahrer schon als unkomfortabel wahrgenommen werden, und umgekehrt. In der Literatur reicht die Beschreibung des Fahrkomforts von einfachem Ableiten der Beschleunigung (Ruck) bis hin zu sog. „full-body biomechanical human models“. <i>Verschiedene</i>, maximale Ruck-Werte können in der Literatur gefunden werden, welche angeben, ob der Passagier das Fahrverhalten als komfortabel oder unkomfortabel einstuft. Wünschenswert wäre eine Beschreibung des Komfortempfindens aufgrund von direkt messbaren Merkmalen, um die umständliche Berechnung über den Ruck oder das „full-body biomechanical human model“ zu umgehen.</p>
Ziel	<p>Ziel der Arbeit ist es, den Fahrkomfort anhand von Merkmalen zu klassifizieren. Dazu ist es notwendig, eine Reihe von Messfahrten mit dem Insitutsfahrzeug und verschiedenen Mitfahrern durchzuführen. Hierbei werden Merkmale gemessen, die zur Klassifizierung verwendet werden können (Position, Geschwindigkeit, Abstand zum vorausfahrenden Fahrzeug, ..). Des weiteren wird die Angabe über den aktuell empfundenen Komfort des Mitfahrers aufgezeichnet. Im Anschluss wird untersucht, mit welchen Merkmalen die best mögliche Klassifizierung des</p> <div data-bbox="614 994 1241 1491" data-label="Figure"> </div> <p>Komforts erreicht wird.</p>
Besonderes	<p>Interesse im Themengebiet Datenanalyse und Automobil Praxis/Messung 40%, Datenanalyse 60%</p>
Betreuerin	Gunda Obereigner

Bachelorarbeit	Recognizing Driving Styles
Hintergrund	<p>It has been generally accepted that different drivers could behave differently during same driving contexts. These different ways drivers choose to habitually drive are known as driving styles. By recognizing the driving styles of different drivers, the interaction between the driving environment and drivers can be more effective and better targeted. Furthermore, the recognition of driving styles can also be helpful to the following aspects which are important to build a more intelligent transportation system:</p> <ul style="list-style-type: none"> (i) Build up more accurate and realistic driving behaviour model by considering various driving characteristics; (ii) Detect and recognize the inconsistent or dangerous driving style such as non-owner driving style, fatigue driving style and drunken driving style; (iii) Provide a quantitative evaluation method and basis for driving skill training and driving style recommendation like eco-driving; (iv) Support the development of Advanced Driving Assistance Systems (ADAS) and provide drivers more personalized service. <p>However, driving style information can not be directly measured or detected. Thus, how to comprehensively and quantitatively analyse the different driving styles becomes a new territory to be further explored.</p> <p>Most of the previous studies only focused on the data of target vehicles such as the speed and acceleration of the target vehicles, and rarely considered the stimulating data from the front vehicles such as range and speed difference. This may cause the discovered driving style information lacking interpretability and distinguishability. Furthermore, the differences in driving conditions such as smooth or congested traffic flow can influence the change of driving styles and should also be considered.</p>
Ziel	<p>The aim of the work is to develop models to stimulating data and driving conditions, to quantitatively extract and recognize different driving styles from real-word driving data.</p> <p>proposed method:(use two topic models of (mLDA) and (mHLDA))</p> <p>mLDA: modified Latent Dirichlet Allocation</p> <p>mHLDA: modified Hierarchical Latent Dirichlet Allocation</p>
Besonderes	<p>Interest in the proposed topic and good programming skills are required.</p> <p>Theory 50%, simulation 50%,</p>
Betreuer	Amin Assadi

Bachelorarbeit	Further Prediction
Hintergrund	<p>A Markov chain is a model that tells us something about the probabilities of sequences of random variables, states, each of which can take on values from some set. These sets can be words, or tags, or symbols representing anything, like the weather. A Markov chain makes a very strong assumption that if we want to predict the future in the sequence, all that matters is the current state. The states before the current state have no impact on the future except via the current state. It's as if to predict tomorrow's weather you could examine today's weather but you weren't allowed to look at yesterday's weather.</p> <p>A Markov chain is useful when we need to compute a probability for a sequence of observable events. In many cases, however, the events we are interested in are hidden: we don't observe them directly. For example we don't normally observe part-of-speech tags in a text. Rather, we see words, and must infer the tags from the word sequence. We call the tags hidden because they are not observed. A hidden Markov model (HMM) allows us to talk about both observed events (like words that we see in the input) and hidden events (like part-of-speech tags) that we think of as causal factors in our probabilistic model.</p>
Ziel	<p>The aim of the work is to develop a model for estimating the existence of the preceding vehicles of the preceding vehicles and also estimating the relative interaction between these two preceding vehicles.</p> <p>proposed method: HMM</p>
Besonderes	<p>Interest in the proposed topic and good programming skills are required.</p> <p>Theory 50%, simulation 50%</p>
Betreuer	Amin Assadi

Bachelorarbeit	Aerial video post processing tools for ADAS
Hintergrund	When it comes to Advanced Driver Assistance Systems in vehicles, vision and image-based ADAS is highly popular since it uses computer vision algorithms such as object recognition, road sign detection, pedestrian detection, lane tracking, parking assistance, vehicle control, collision warning, etc., to assist in safe and smart driving.
Ziel	<p>The aim of the work is to develop post processing toolbox which prepare high quality dataset from an aerial videos.</p> <p>Tasks:</p> <ol style="list-style-type: none"> 1. Video Stabilization 2. Video Rectification 3. Road Lines Detection and Mapping 4. Vehicle Detection and Tracking
Besonderes	<p>Interest in the proposed topic and good programming skills are required.</p> <p>Theory 40%, Programming 50%, Practice 10%</p>
Betreuer	Amin Assadi

Bachelorarbeit	Stochastic traffic flow prediction based on real-world data
Hintergrund	<p>The traffic looks chaotic and changing all the time. But from a macroscopic view, some patterns can be observed for different location, different time, different weather, etc. These information has the potential to facilitate people in daily driving, for example customizing the most suitable travel plan. However, the traffic patterns are usually stochastic and influenced by many factors. How to describe it in a stochastic way? How to predict the traffic flow relatively accurately, and utilize this information to benefit drivers' travelling?</p> <div style="display: flex; justify-content: space-around;">   </div>
Ziel	<p>The aim of this work is to collect traffic data, build a traffic flow prediction model, formulate and solve an optimal problem which minimizes total travel time.</p> <p>To be more specific, assume one employee goes to work every day by car, and he has to be in the office before certain time. He can set out anytime in the morning in certain time range, but based on different traffic every weekday, the travel time may be also differ. The student needs to find out the best time to set out, so that the employee spends least time on the road.</p>
Besonderes	<p>The student should be interested in designing a plausible experiment, formulate an optimal problem and provide corresponding solution. Programming skills are needed.</p> <p>Theory 30%, data analysis 40%, simulation/modelling 30%.</p>
Betreuer	Junpeng Deng