

# Stochastische Generierung der Fahrdynamik

Bachelor Arbeit

Vinzenz Roth

Betreuung: Dr. Pavlo Tkachenko

Endpräsentation

16.09.2019



Institute for Design and Control of Mechatronical Systems



JOHANNES KEPLER  
UNIVERSITY LINZ

# Overview

- Motivation
- Anwendungen von GANs
- Probleme beim Training von GANs
- Validieren der Kostenfunktionen
- Analyse der Datensätze
- Training der GANs
- Simulation von Resultaten

# Autonomous mobility

- Zukunft und Trend müssen nicht hervorgehoben werden
- Technische Voraussetzungen erfordern keine große Komplexität
  - Erkennen des Fahrbahnrandes
  - Automatisch Lenken und Bremsen
  - Klassifikation der Straßenschilder
- Prüfung der Sicherheit, Verlässlichkeit, Stabilität
  - Vor Kommerzialisierung der Fahrzeuge
  - Bei jedem Hardware- und Softwareupdate


# on-road testing

- Hunderte von Millionen Kilometern erforderlich um statistische Aussage für Sicherheit zu treffen [1]

# virtual testing

- ✓ Skalierbarkeit
- ✓ Fast-Unfall-Szenarien
- ✓ Szenarien mit unvermeidlichen Unfall
- ✓ Reproduzierbarkeit der Events
- ✓ verringerter Zeit- und Kostenaufwand

# Generate random but realistic traffic scenarios for validation of advanced driver assistance systems (ADAS)




# GAN applications I


## Text to Image Translation [2]

The small bird has a red head with feathers that fade from red to gray from head to tail

Stage-I  
images



Stage-II  
images



This bird is black with green and has a very short beak

Stage-I  
images



Stage-II  
images



## Super Resolution [3]

bicubic










SRResNet



SRGAN



original



# GAN applications II

3D Object Generation [4]





Image to Image Translation [5]




Generate Photographs of Human Faces [6]




# Problems of Training GANs

## Modellzusammenbruch [7]








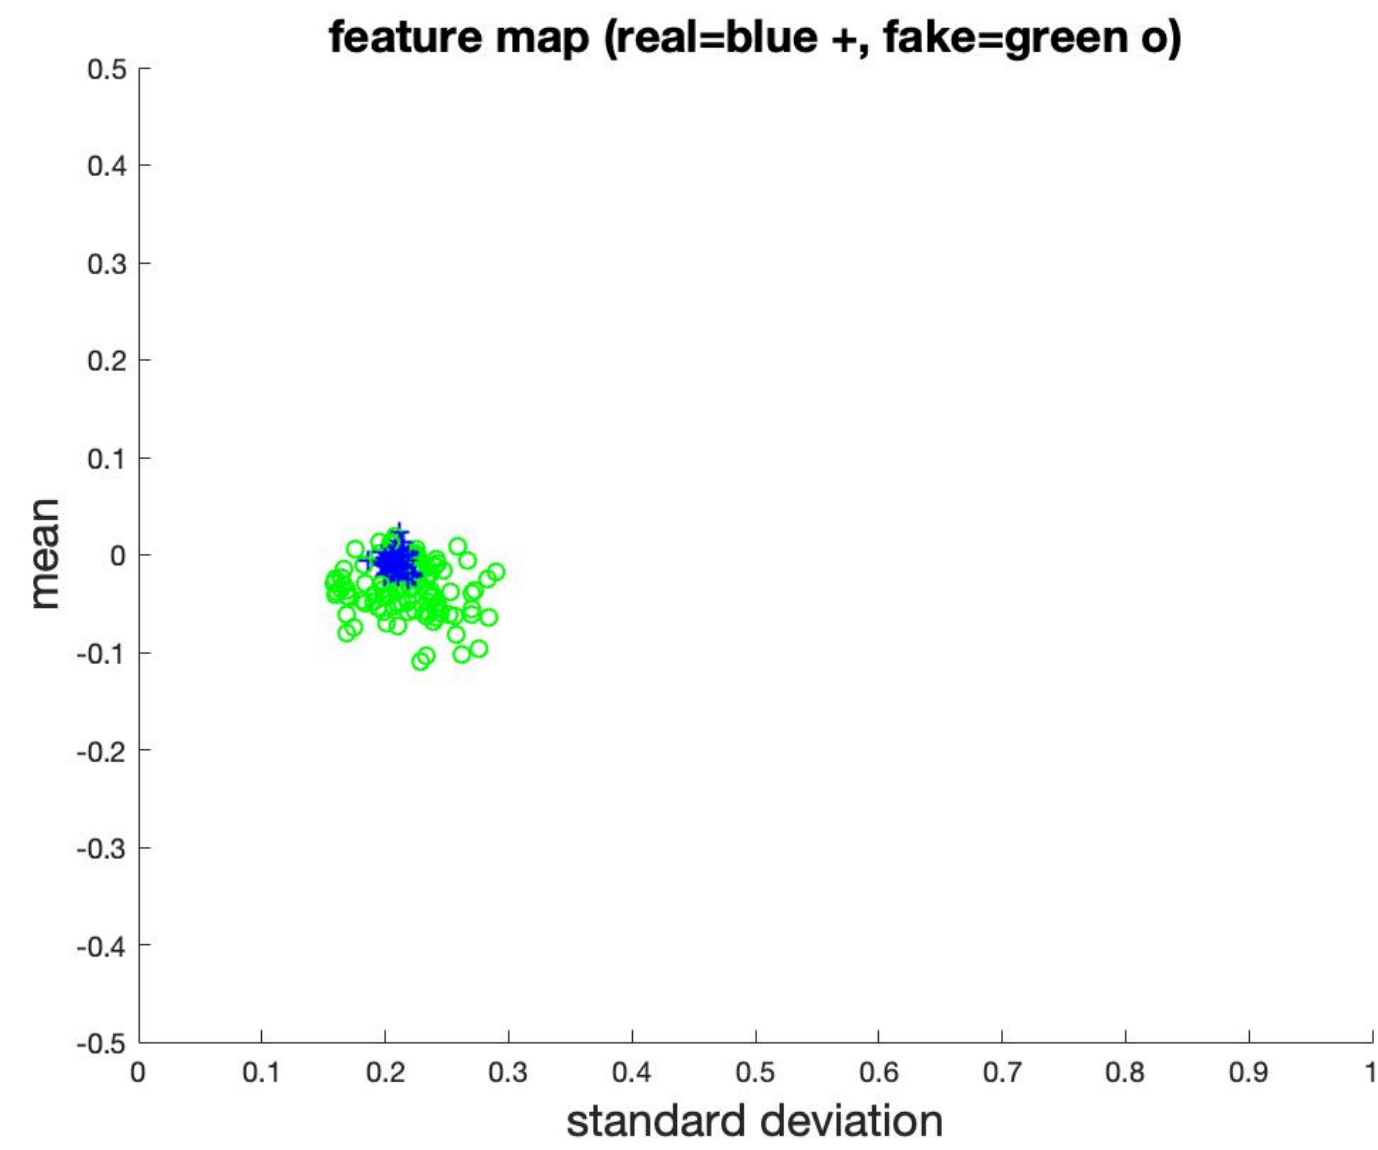
- Keine Konvergenz
- Ungleichgewicht der Netzwerke
- Empfindlich gegenüber Hyperparameter

## Verringerte Steigung [8]

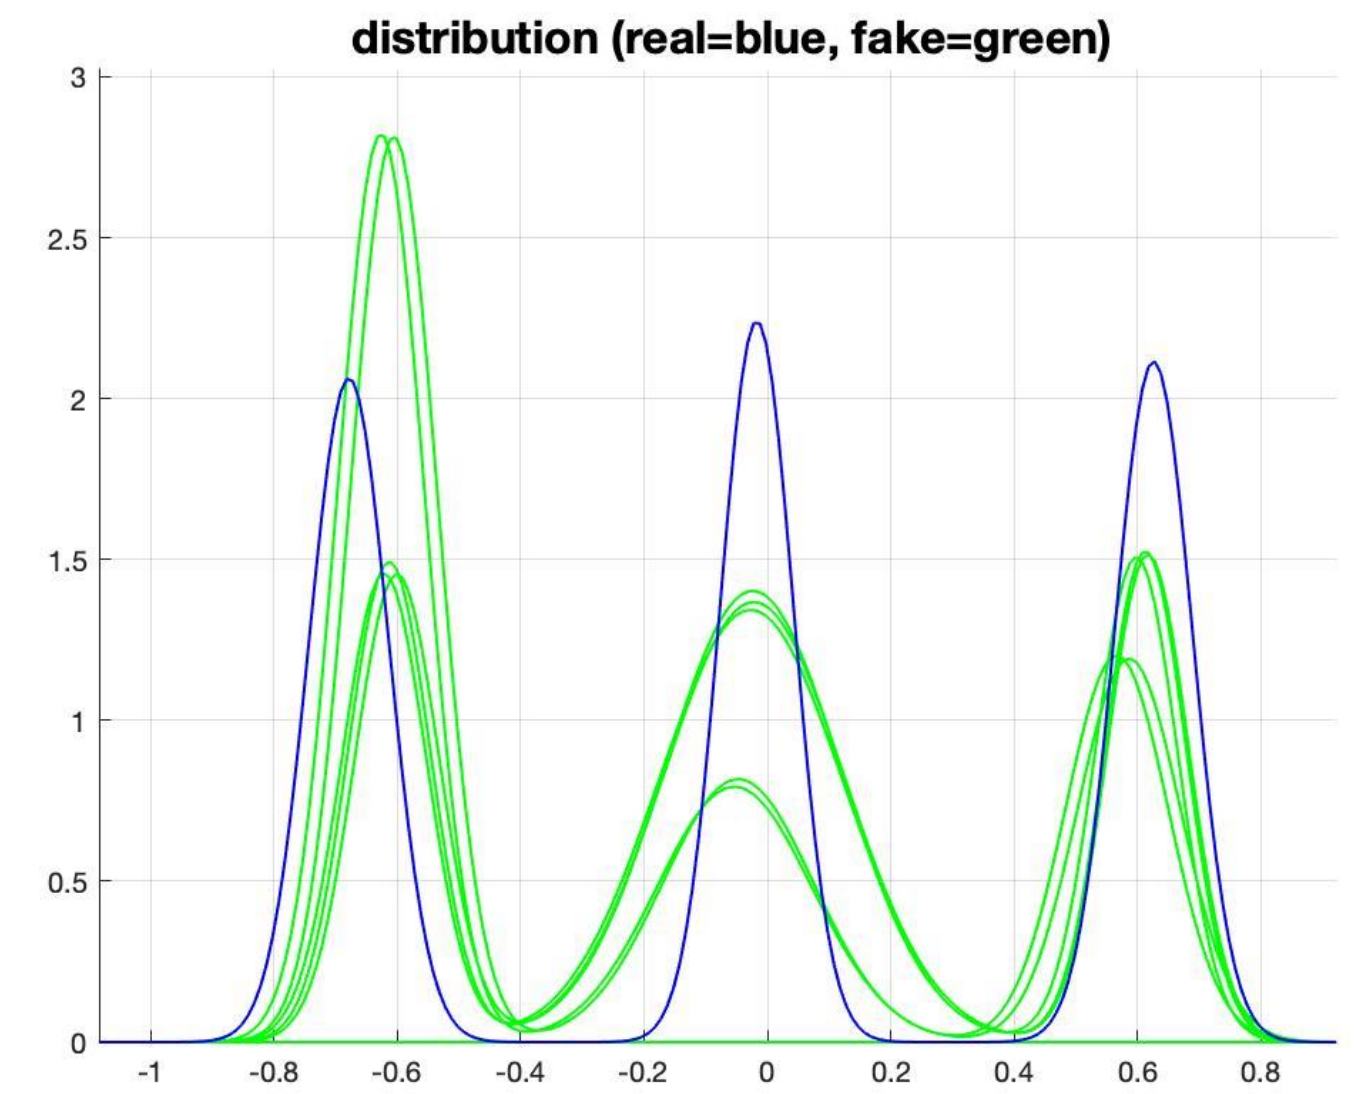
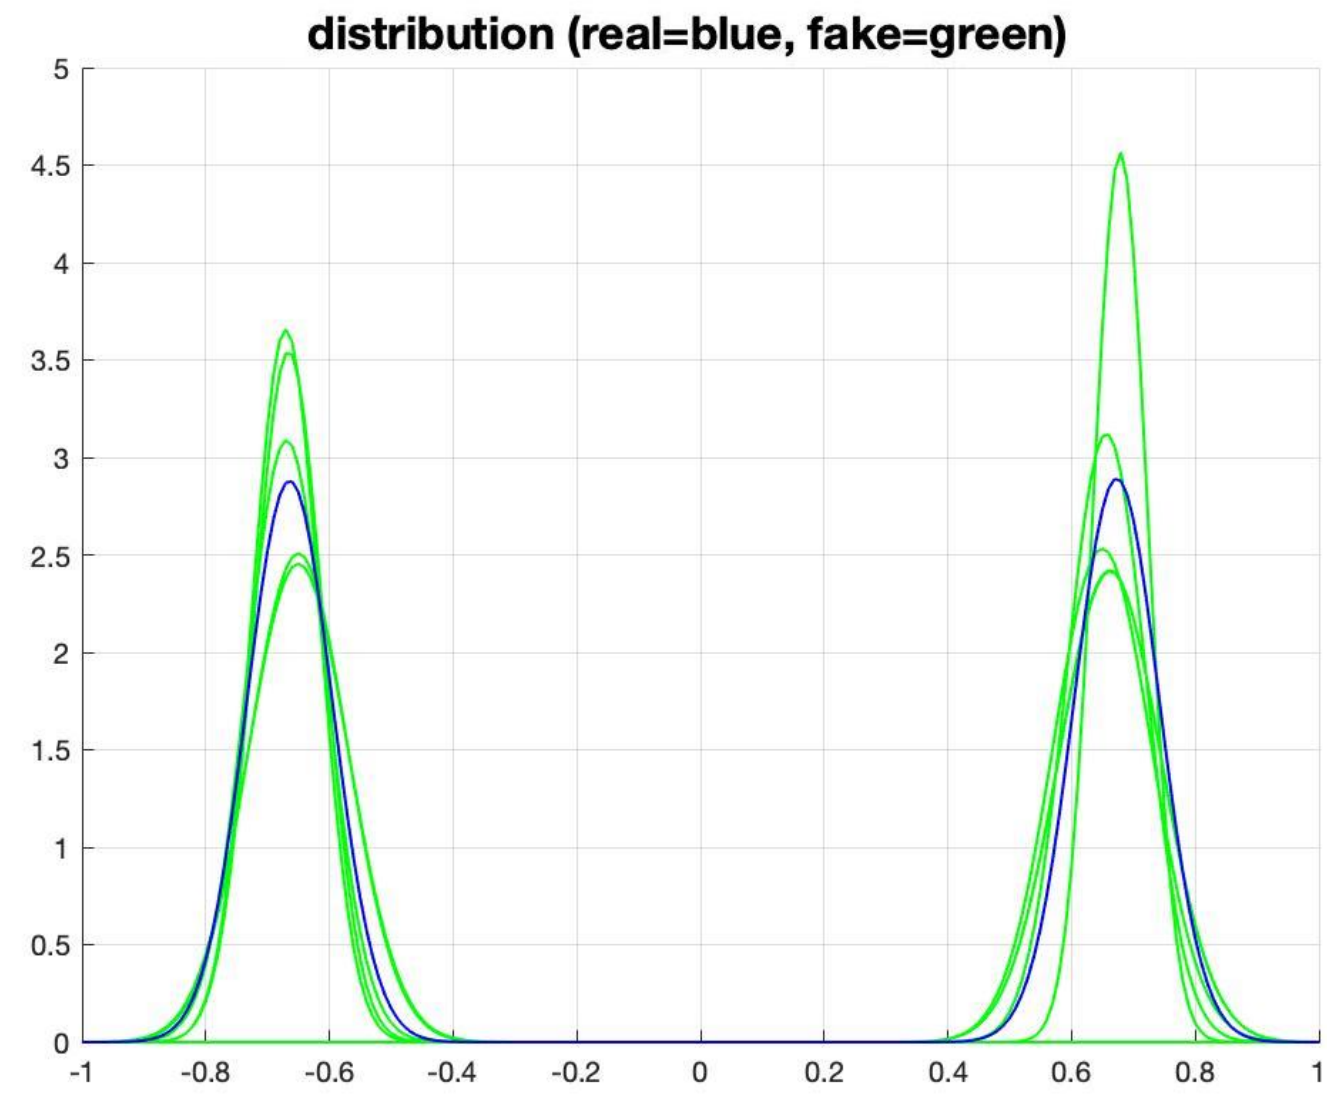

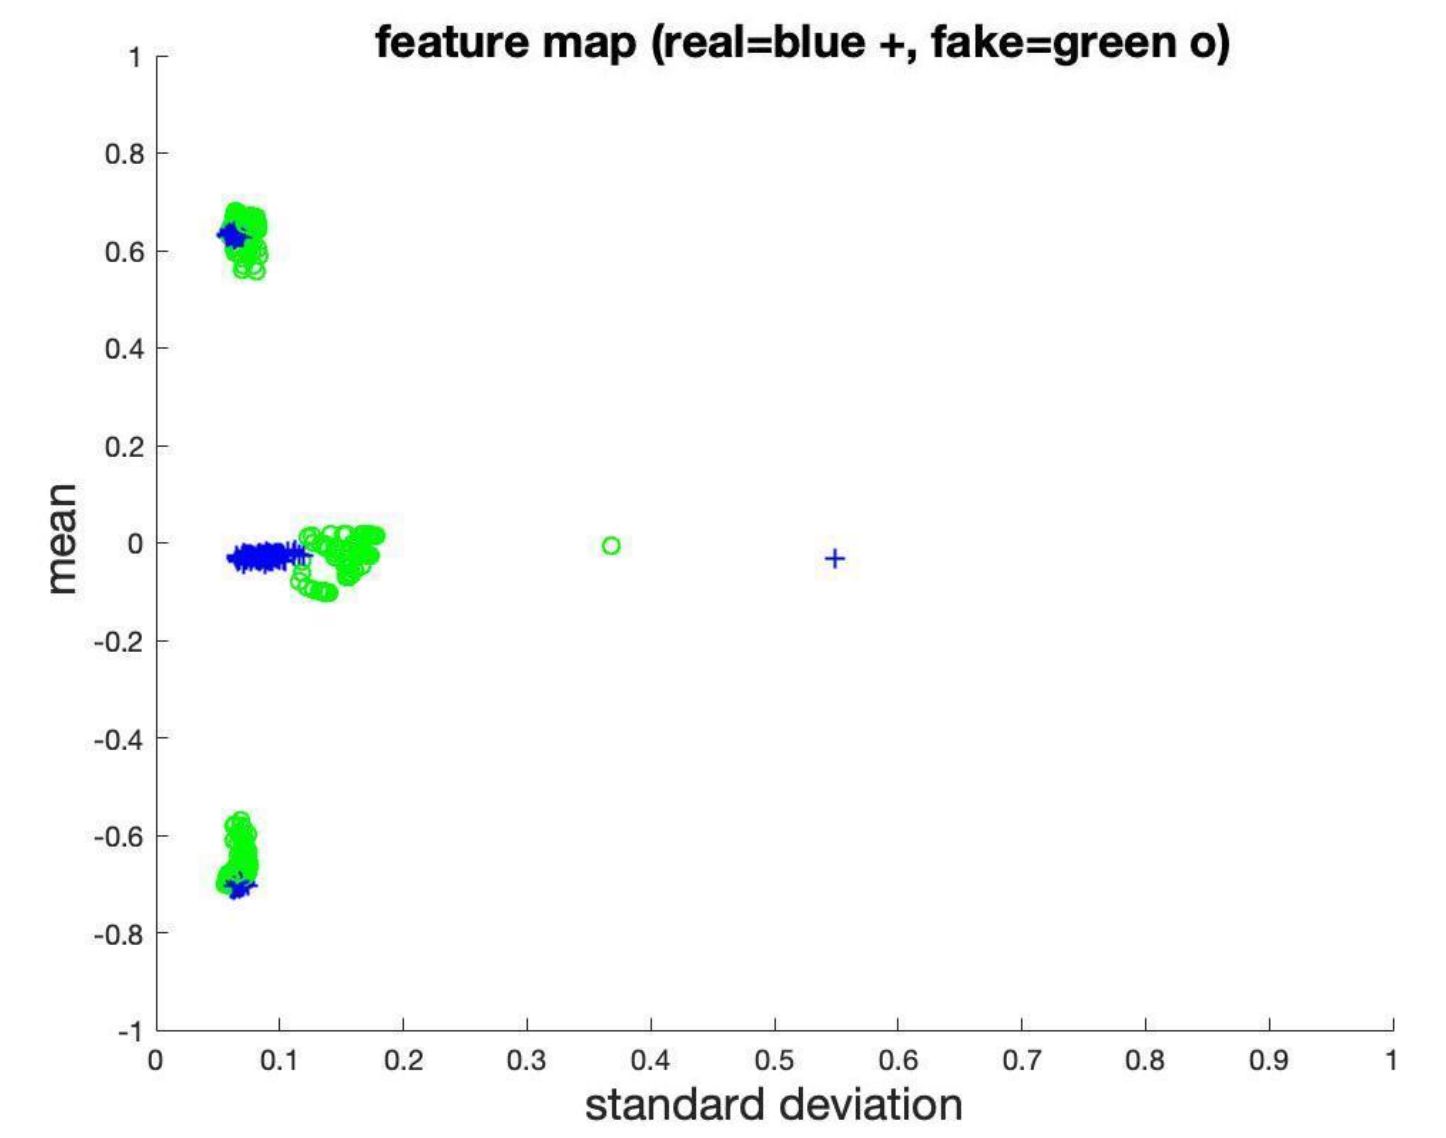







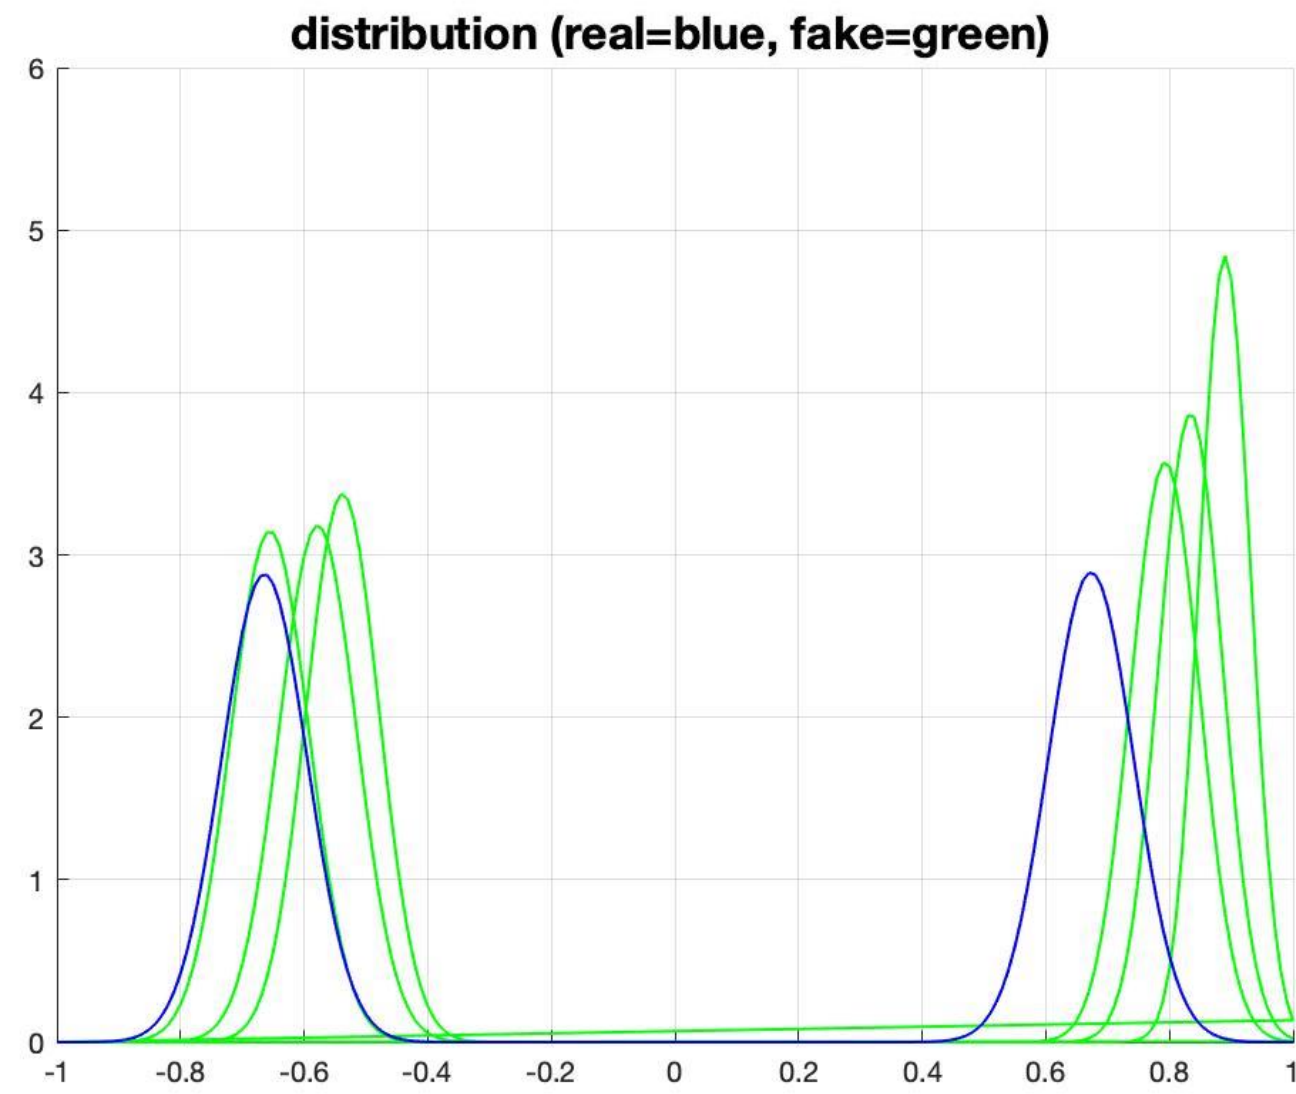
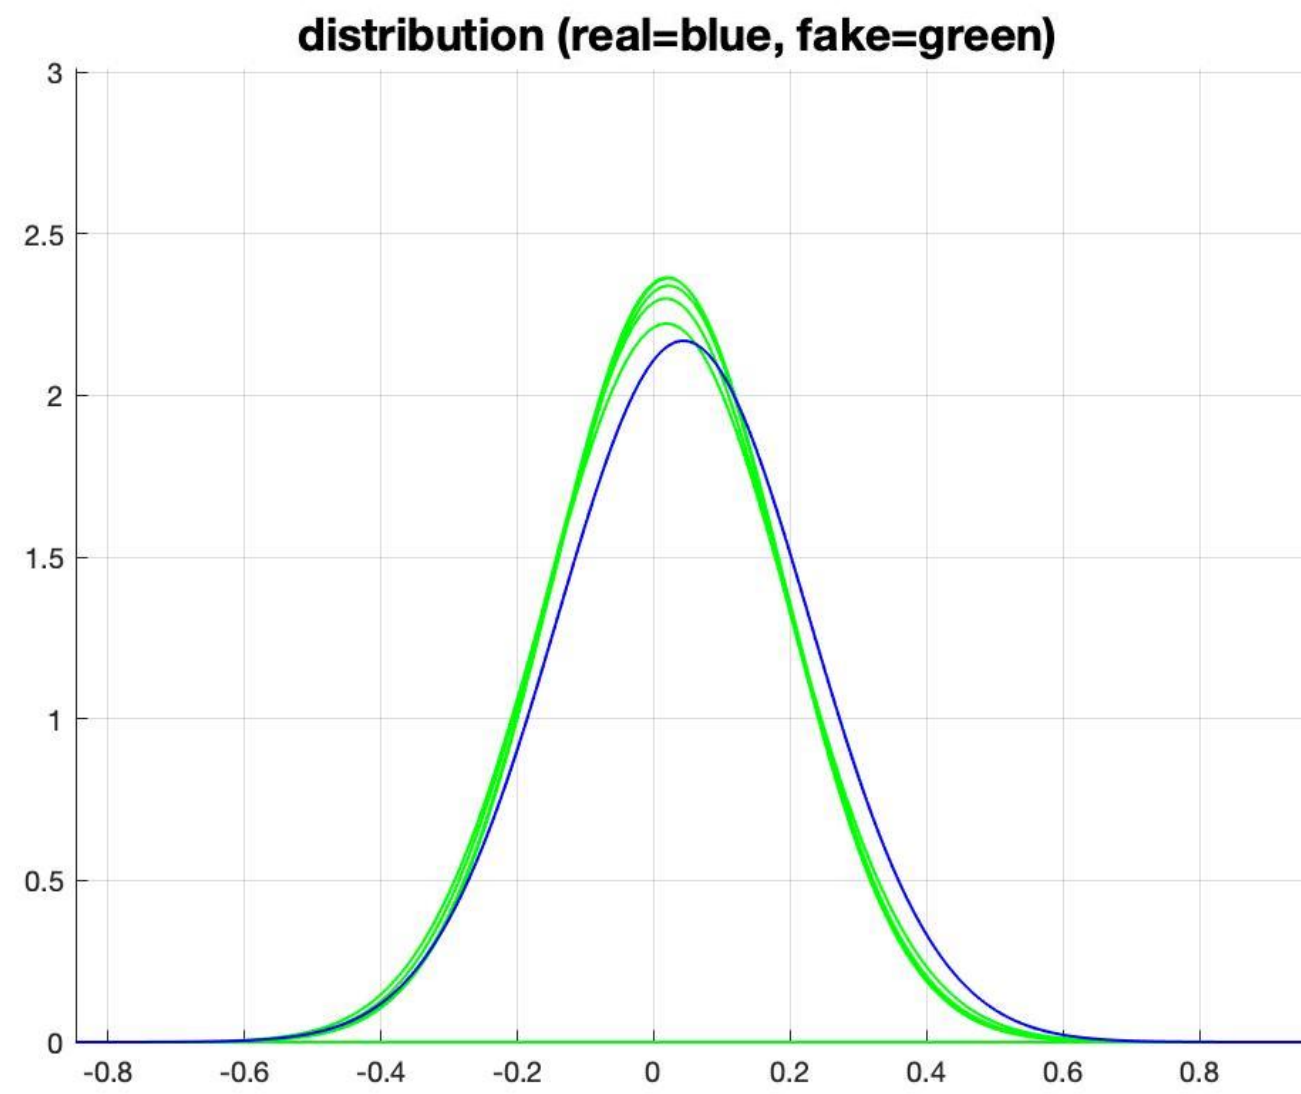
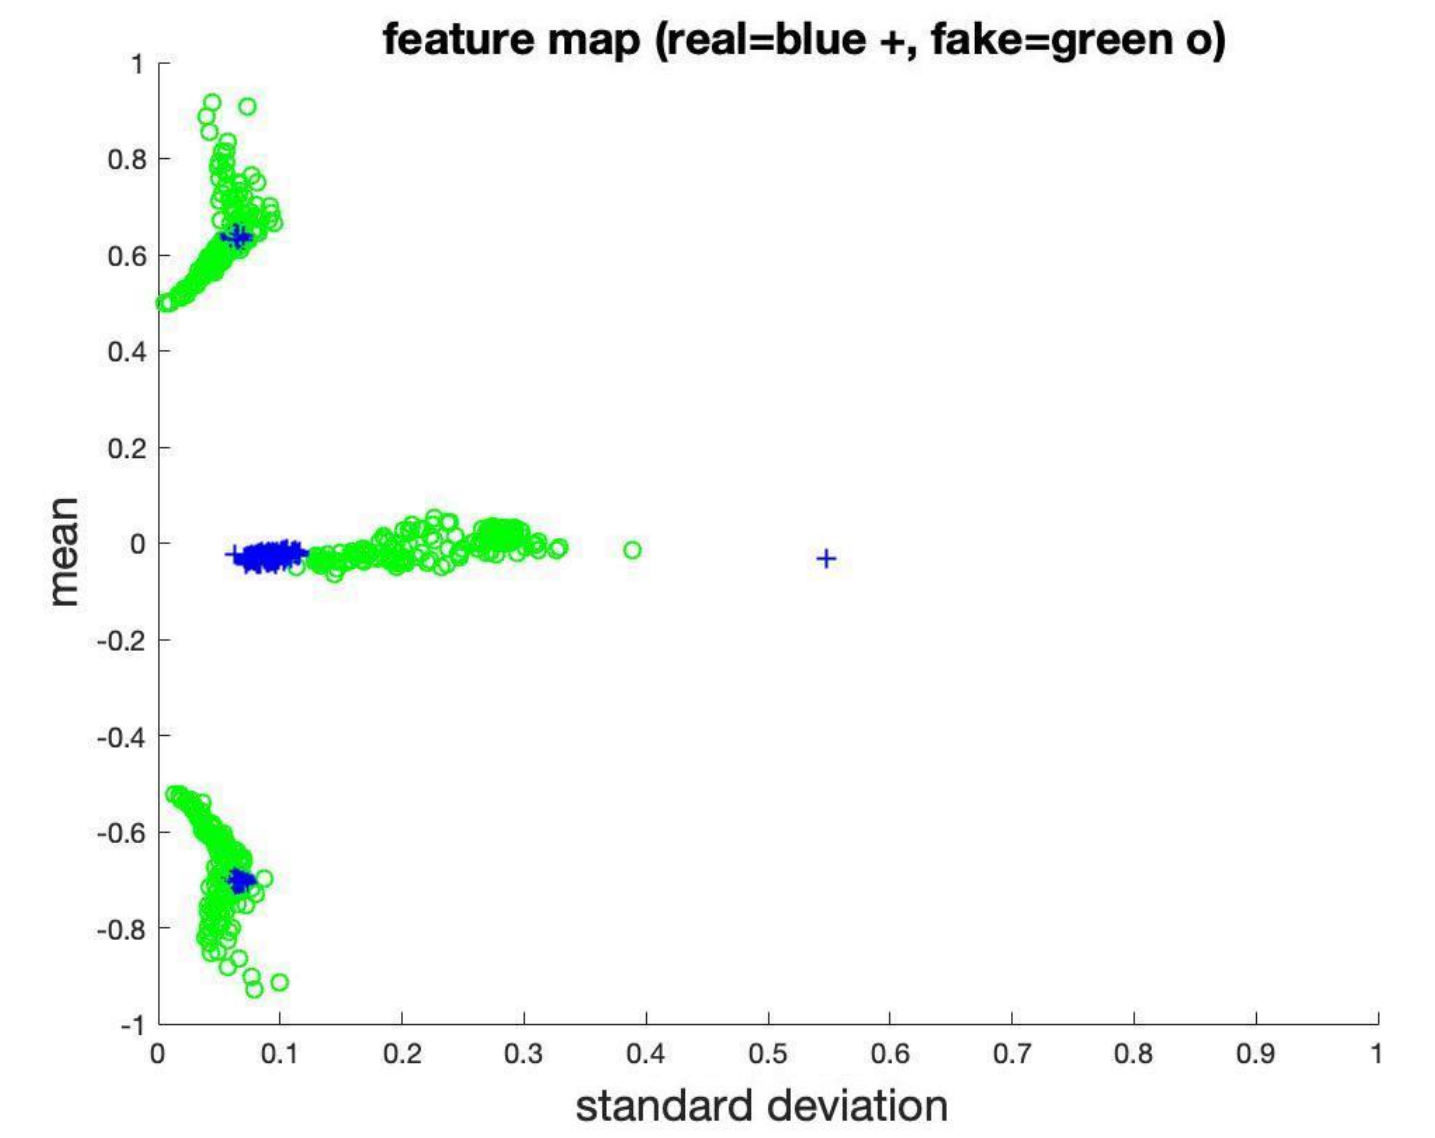


# Validation: Standard GAN



# Validation: WGAN





# Validation: WGAN GP





# italy

- ca. 940 Minuten Fahrt
- Sample Time 0,5 Sekunden
- Erstellung von 196 Samples mit jeweils 288 Sekunden Fahrt (4,8 Minuten)
- Samples mit Verlauf der Geschwindigkeit und Abstand zum Fahrbahnrand
- Samples untereinander sehr verschieden siehe feature map
- Rauschen wird beim Training modelliert
- Nicht sehr gut geeignet für GANs




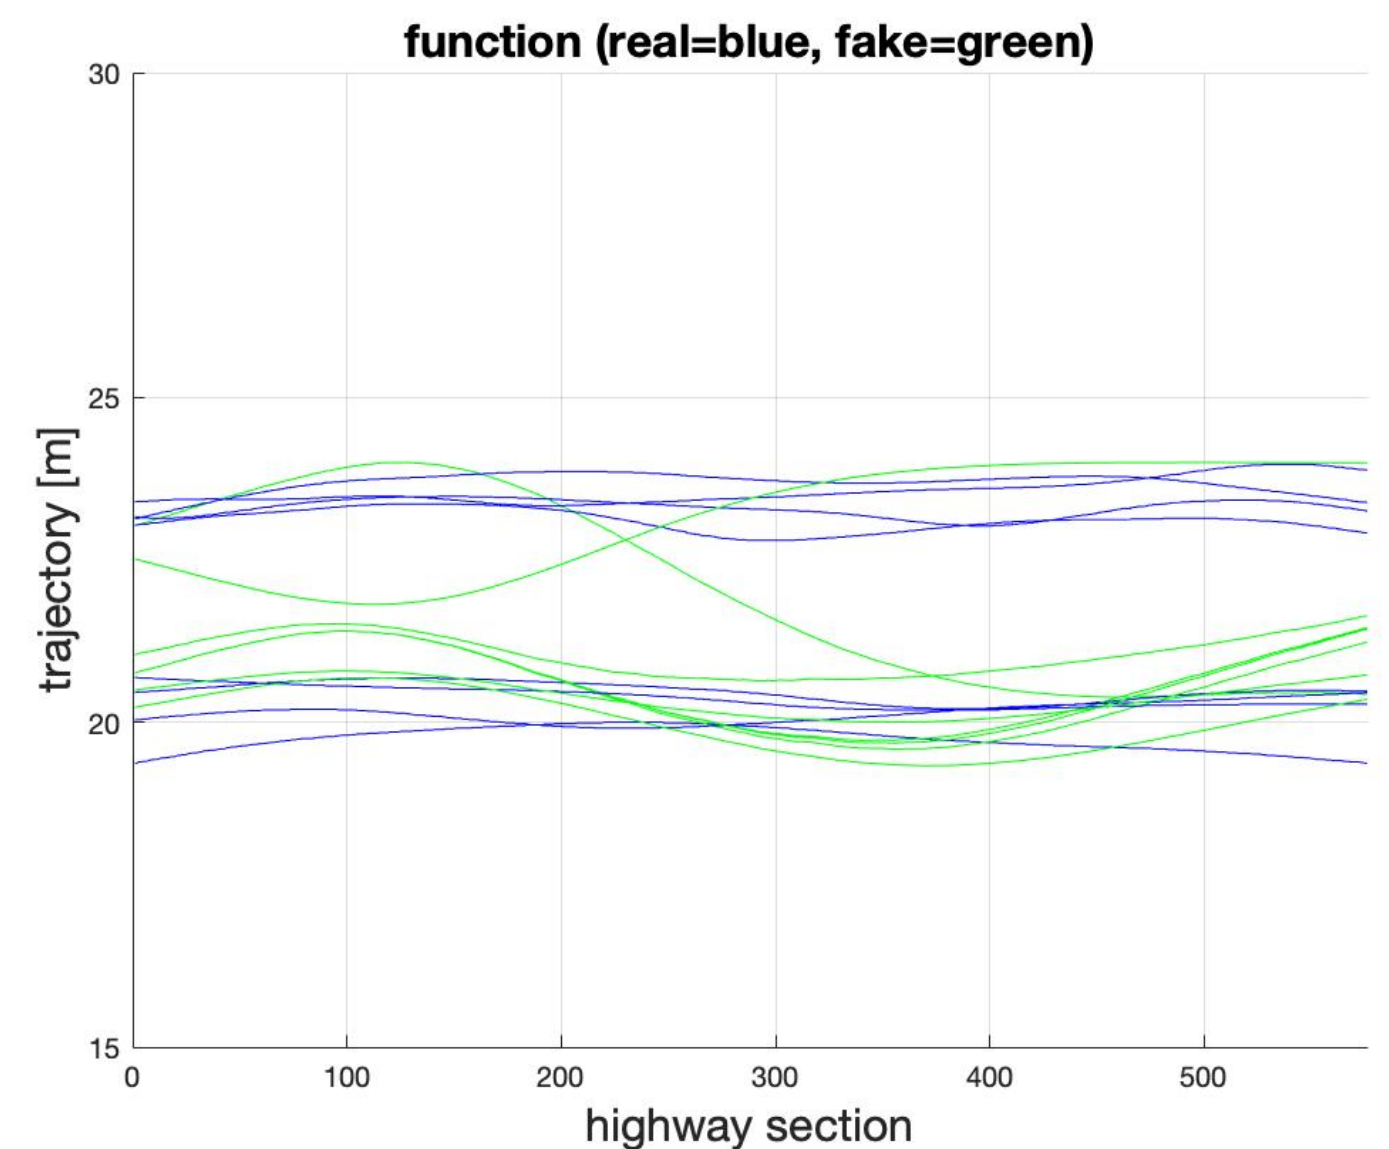


# highD

- Highway Drone Dataset mit jeweils ca. 420m dreispurigen Abschnitten
- Umfasst insgesamt 110500 Fahrzeuge
- Samples mit Trajektorie und Geschwindigkeitsverlauf von jedem Fahrzeug
- Daten konzentriert in feature map verteilt, außer Spurwechseltrajektorien
- Beliebige Kombination der Samples untereinander







# Separates Training: Trajektorien

- Beschränkung auf Trajektorien von unteren beiden Fahrstreifen inklusive Spurwechsel
- WGAN (links) deutlich konzentrierter bei Spurhaltetrajektorien
- WGAN GP (rechts) vermehrte Spurwechseltrajektorien
- etwas wellige Trajektorien beim WGAN
- Spurwechsel beim WGAN GP sehr realitätsgetreu




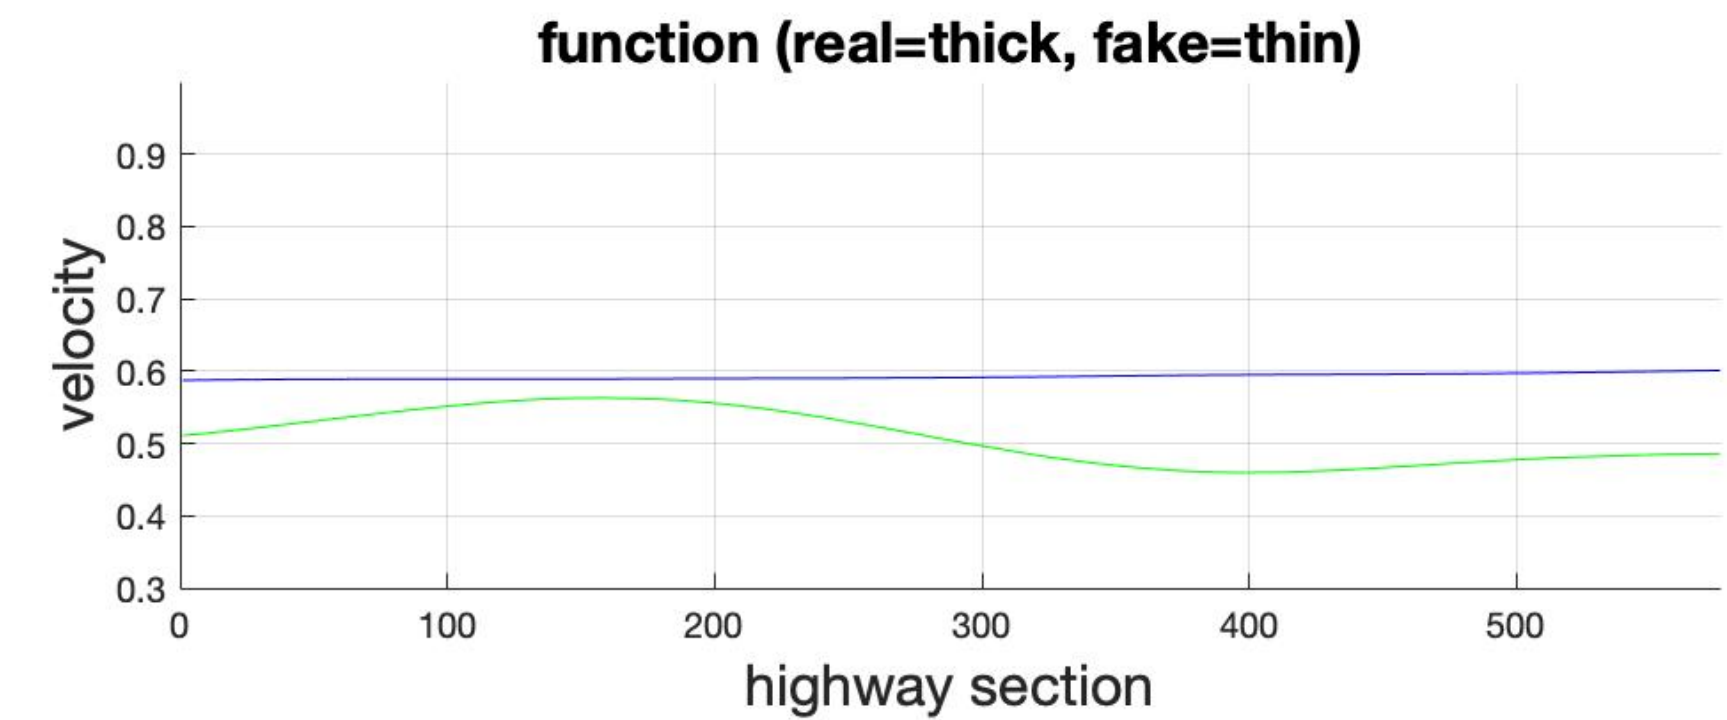
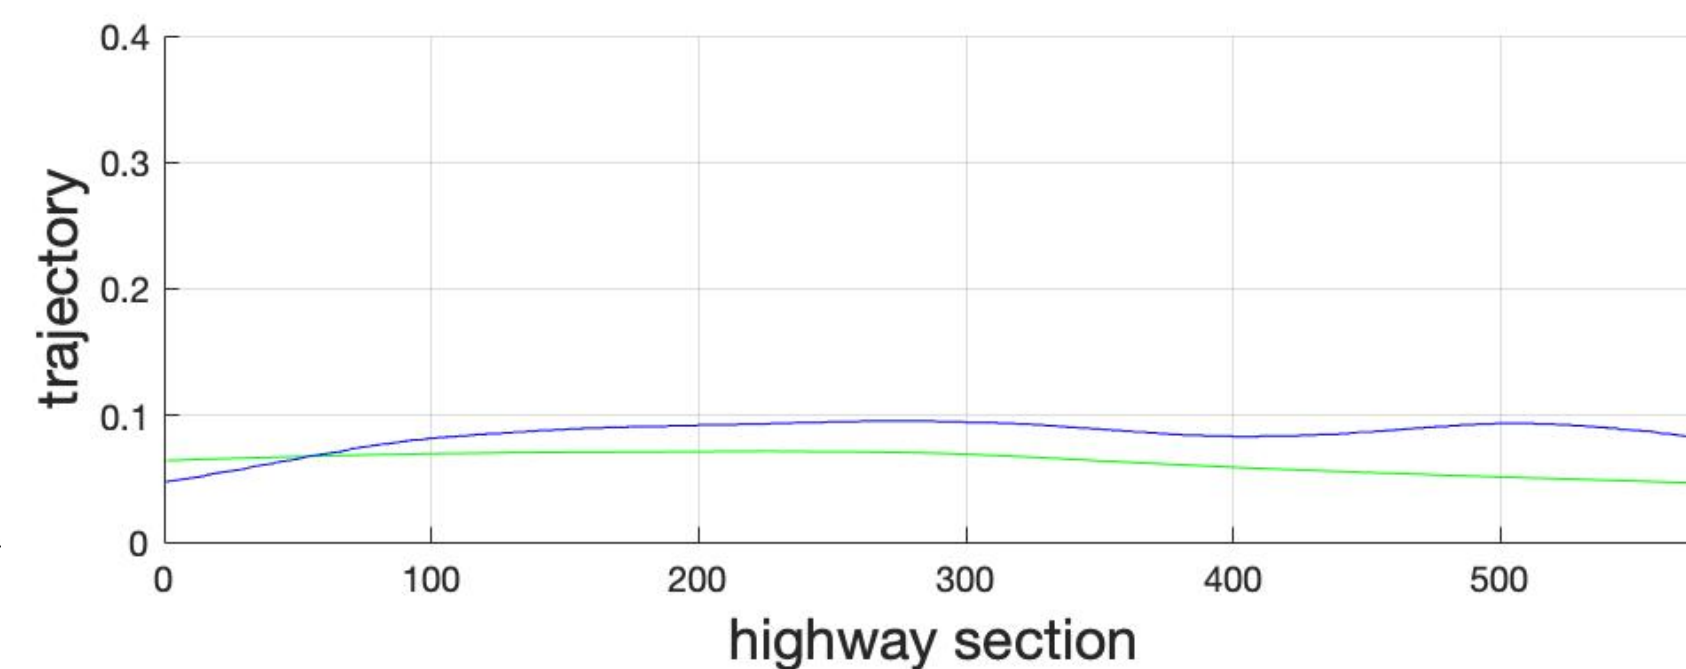


# Separates Training: Geschwindigkeit

- Geschwindigkeitsverläufe von allen Fahrbahnen
- WGAN (links) stärker ausgeprägt im oberen Bereich des Mittelwertes
- WGAN GP (rechts) nimmt sehr gut Form der Zielverteilung an
- eher wellige Verläufe beim WGAN da in echten Daten auch Ausreißer vorhanden
- realitätsgetreue Abbrems- und Beschleunigungsvorgänge beim WGAN GP



# Simultanes Training: Eine Fahrbahn






- Kombination aus Geschwindigkeit und Trajektorie eines Fährsteifens
- Einfügen der Samples in einen Datensatz
- WGAN GP-Konfiguration
- Fall 1 (links): Leichte Beschleunigung + konstanter Spurhaltevorgang
- Fall 2 (rechts): Abbremsvorgang + welliges Halten der Spur






# Simultanes Training: Zwei Fahrbahnen

- Verwendung der Geschwindigkeitsverläufe und Trajektorien zweier Fahrbahnen
- Einfügen der Samples in einen Datensatz (wieder doppelte Anzahl von Samples)
- WGAN-Konfiguration
- Fall 1 (links): stockiges Abbremsen + rascher Spurwechsel
- Fall 2 (rechts): Beschleunigungsvorgang + wellige Spurhaltetrajektorie



# Simultanes Training: Zwei Fahrbahn

- Verwendung der Geschwindigkeitsverläufe und Trajektorien zweier Fahrbahnen
- Zusammenfügen der Kandidaten in ein Sample (Sample Anzahl erhöht sich nicht)
- WGAN-Konfiguration
- Fall 1 (links): Starkes Beschleunigen + stetiger Spurwechsel
- Fall 2 (rechts): Leichter Abbremsvorgang + fast konstantes Halten der Spur



# Simulation



# Literatur- und Quellenangabe

- (1) Kalra, Nidhi & Paddock, Susan. (2016). Driving to safety: How many miles of driving would it take to demonstrate autonomous vehicle reliability?. *Transportation Research Part A: Policy and Practice*. 94. 182-193. 10.1016/j.tra.2016.09.010.
- (2) Zhang, Han & Xu, Tao & Li, Hongsheng & Zhang, Shaoting & Huang, Xiaolei & Wang, Xiaogang & Metaxas, Dimitris. (2016). StackGAN: Text to Photo-realistic Image Synthesis with Stacked Generative Adversarial Networks.
- (3) Ledig, Christian & Theis, Lucas & Huszar, Ferenc & Caballero, Jose & Aitken, Andrew & Tejani, Alykhan & Totz, Johannes & Wang, Zehan & Shi, Wenzhe. (2016). Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network.
- (4) Wu, Jiajun & Zhang, Chengkai & Xue, Tianfan & Freeman, William & Tenenbaum, Joshua. (2016). Learning a Probabilistic Latent Space of Object Shapes via 3D Generative-Adversarial Modeling.
- (5) Zhu, Jun-Yan & Park, Taesung & Isola, Phillip & Efros, Alexei. (2017). Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. Arxiv.
- (6) Karras, Tero & Aila, Timo & Laine, Samuli & Lehtinen, Jaakko. (2017). Progressive Growing of GANs for Improved Quality, Stability, and Variation.
- (7) Metz, Luke & Poole, Ben & Pfau, David & Sohl-Dickstein, Jascha. (2016). Unrolled Generative Adversarial Networks.
- (8) Jonathan Hui. Why it is so hard to train GANs. ([https://medium.com/@jonathan\\_hui/gan-why-it-is-so-hard-to-train-generative-advisory-networks-819a86b3750b](https://medium.com/@jonathan_hui/gan-why-it-is-so-hard-to-train-generative-advisory-networks-819a86b3750b)) Abgerufen am 6. September 2019.