

高齢ドライバーの Dynamic steering skills を評価するためのシミュレータの開発

代表研究者

梶原 祐輔

公立小松大学生産システム科学部 准教授

1 はじめに

高齢ドライバーによる交通事故を防ぐために免許更新時に認知機能検査に加え、事故を起こした高齢者の「運転技能検査」が義務化された。一方、運転技能を評価できる検査員や場所の確保が難しいため、すべての高齢ドライバーに検査できていないのが現状である。

以上の背景から、応募者は検査員の代わりにAIがシミュレータ上の運転行動から運転技能が低い高齢ドライバーをスクリーニングする技術を開発した(図1)。そしてこれに係る技術の特許を取得/実用化し、その成果を論文

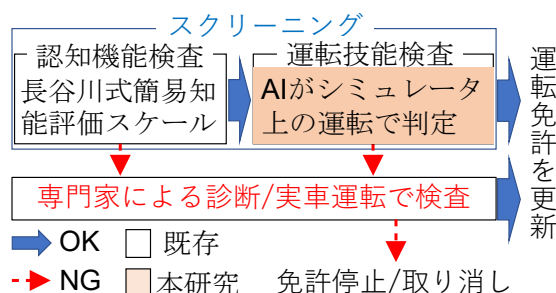


図1 運転技能のスクリーニング検査の実現

で発表した[1][2]。残る課題はシミュレータの生成である。シミュレータの要件は①多種多様なコースの生成、②現実世界のルールや現象の再現、③運転技能を評価できるシーンの生成である。①によりテスト対策などによる検査の感度低下を防ぎ、②によりシミュレータ上の運転と実車での運転の差異をなくし、③により運転技能を測る。一方、これらの要件を満たすシミュレータは専門家しか生成できず、開発/導入コストが高い。この問題を、応募者はAIによるシミュレータ自動生成技術で解決する。既に要件①を満たすシミュレータの自動生成には成功した[3][4]。

本研究はAIによるシミュレータの自動生成システムの開発を目的に掲げる(図2)。ドライブレコーダには高齢ドライバーの生活圏内の運転風景が記録されており、この動画はクラウド上にアップロードされる。そして、AI技術の一種の敵対的生成ネットワーク(GAN)にドライブレコーダの動画を学習させ、シミュレータを自動生成する。生成したシミュレータはクラウドを通して配信され、ブラウザ上で再生される。高齢ドライバーはアクセル・ブレーキ・ハンドル型インターフェースを使い、シミュレータ上のコースを周回する。運転技能は応募者の特許「運転者適性評価システム」により、シミュレータで運転したさいの視線、ブレーキ・ステアリング操作などからAIが自動的に判定する。

本研究のシミュレータ自動生成技術を高齢ドライバーの運転免許時のスクリーニング検査に活用することで、効率的な検査の実現とコスト削減が期待できる。自動車学校や自宅で活用することで高齢ドライバーの生活圏における安全運転指導や危険予測訓練ができる。本研究成果は市民が安全・安心に暮らせる社会の実現に貢献し、大きな社会的価値を創造する。

本研究のシミュレータ自動生成技術を高齢ドライバーの運転免許時のスクリーニング検査に活用することで、効率的な検査の実現とコスト削減が期待できる。自動車学校や自宅で活用することで高齢ドライバーの生活圏における安全運転指導や危険予測訓練ができる。本研究成果は市民が安全・安心に暮らせる社会の実現に貢献し、大きな社会的価値を創造する。

本研究のAIによるシミュレータの自動生成技術により専門家以外でも現実世界のデータに基づいたデータ駆動型シミュレータが生成可能になる(図3)。この技術は災害時の避難シミュレータや都市の3Dデジタルマップの自動生成、メタバースやオンライン観光における仮想空間の自動生成などに活用でき、デジタル



図2 AIによるシミュレータの自動生成の流れと活用

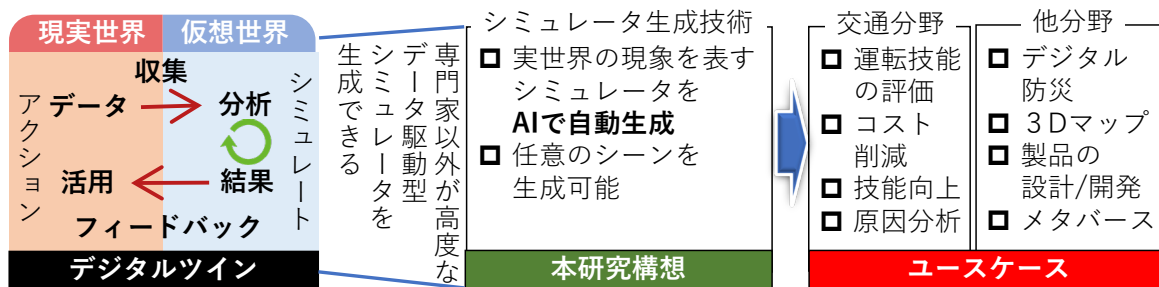


図3 本研究のAIによるシミュレータ自動生成技術が学術/科学技術/社会にもたらす波及効果

ツイン・DXを促進させる。AIによるシミュレータの自動生成技術は交通分野のみならず、防災・建築・観光分野への波及効果をもたらす。

2 関連研究

2-1 専門家によるドライビングシミュレータの開発

ドライビングシミュレータはコンピュータグラフィックス (CG や走行映像をもとに専門家により作成される。CG によるドライビングシミュレータの作成ではシミュレーション空間内で3Dモデルを構築される。また、企業でもドライビングシミュレータの開発は行われ、360度カメラで撮影した走行映像を使用してドライビングシミュレータを生成する True Sim (実車映像再生ソフトウェア) や、自動運転実現で注目を集める LiDAR (Light Detection And Ranging) によるシミュレータの開発も行われている。CG 技術を用いたドライビングシミュレータはコンピュータゲームや自動車教習所等で使用されている。コンピュータゲームで使用されるドライビングシミュレータでは、自動車の実際の挙動をできるだけ忠実に模擬し実在のサーキットでの運転やレースを疑似体験することができるもの[5]、一般の人が普段運転をすることは困難な乗り物(バス、トラック等)の運転することができるもの[6]等がある。また、自動車教習所等で、主に教習生が自動車の運転を学ぶために使用されている運転練習用のドライビングシミュレータでは、実車を用いると危険が伴う可能性の高い急制動の練習や、地域によっては練習の困難な高速道路や雪道の運転練習、危険予測の練習などに使用されることが多い。しかし、CG で作成されたドライビングシミュレータには、ドライビングシミュレータのカスタマイズ、シナリオ作成に掛かる負担が大きいことが課題となっている[5]。走行映像を使用したドライビングシミュレータである True Sim[6]は、株式会社東陽テクニカと岩根研究所がカメラベクトル技術を応用して共同で開発した実車映像再生ソフトウェアである。True Sim では360度カメラで撮影した走行映像に対して特徴点などの各種情報を抽出し、撮影時のカメラ視点角度の映像だけでなく、撮影時とは異なるカメラ視点角度からの映像に変換して再生することができる。また、車速やステアリング操舵に連動して映像を再生することもできる。しかし、このソフトウェアを使用するには360度カメラ等の専用機器が必要である。さらに、その映像を加工する必要があるため、一般家庭で利用するのは難しいことが課題である。

2-2 生成系AIによるドライビングシミュレータの生成

GAN を用いたシミュレータの開発が行われている。GAN とは、敵対的生成ネットワーク (Generative Adversarial Network) のことで、2014年に Goodfellow らによって提唱されたニューラルネットワーク (Neural Network NN) の教師なし学習の手法である。GAN は生成器と識別器で精度を競い合い、その精度を高める方法である。生成器は識別器が生成した画像を本物の画像と誤って識別するように、本物の画像に似せて偽画像を生成するパラメータを学習する。識別器は生成器が生成した画像に対して偽画像と判定するように、パラメータを学習する。また、2019年には Karras らによって提唱された GAN の一種である Style GAN [7]では、高解像度の画像を生成することが可能となった。2020年に Kim らによって提唱された Game GAN[8]は、GAN を活用してゲームのプレイ映像とキーボード操作を学習することでコンピュータゲームエンジンを模倣する初のニューラルネットワークモデルである。Game GAN はエージェントのキー入力によって、次のシーンをレンダリングすることでシミュレータの生成を可能にした。2021年に Game GAN と同著者の Kim らによって提唱された Drive GAN [9]は、車で撮影した運転映像から抽出した画像と、車のスピードや




図4 シミュレータ自動生成

車体の角速度などのデータを学習することで、ドライビングシミュレータを自動生成する。DriveGANはエージェントのキー入力によって、スピードやステアリングが制御された次のシーンが生成される。DriveGANの構造は主に、エンコーダ、Dynamics Engine、ジェネレータの三つで構成されている。まず、エンコーダでは変分オートエンコーダVariational Auto Encoder(VAE) [10]とStyleGANを組み合わせたVAEGANを用いて運転映像から抽出した画像を生成する。VAEは背景の色や天候を指す潜在変数 z_{theme} と空間の要素を指す潜在変数 $z_{content}$ を生成する。エンコーダで事前学習して生成された二つの潜在変数をもとに、Dynamics Engineでは時系列データを学習することができるLong Short Term Memory(LSTM) [11]に、車のスピードや車体の角速度と潜在変数 z_t を入力し、次の時間 $t+1$ の潜在変数 z_{t+1} を予測する。Dynamics Engineで生成された潜在変数 z_{t+1} をもとに、ジェネレータでは次のシーンの画像が生成される。そしてこの車体の動きをコントローラと紐づけることで、コントローラ操作に合わせて動画を変化させることができる。これらの三つの機能により、DriveGANはドライビングシミュレータを生成する。しかし、取得データ内にあるパターン以外の操作をコントローラで行った場合に、画像の生成精度が著しく低下する。

3 手法

3-1 データの取得

図4のドライビングシミュレータの生成には「運転映像」、「車のスピード」、「車体の角速度」、「アクセル量」、「ハンドルの回転角」の5つのデータが必要である。運転映像は自動車に搭載されているドライブレコーダや一般的に普及されているカメラで得ることができ、その映像から抽出した画像を用いる。車のスピードはGNSSレシーバーを用いて得ることができ、車体の角速度やアクセル量、ハンドルの回転角は角速度や傾斜角を測ることができるセンサーを用いて得ることができる。これらのデータをDriveGANに入力し、AIモデルを構築する。

3-2 自動車の運転モデルを用いたオーバーサンプリング

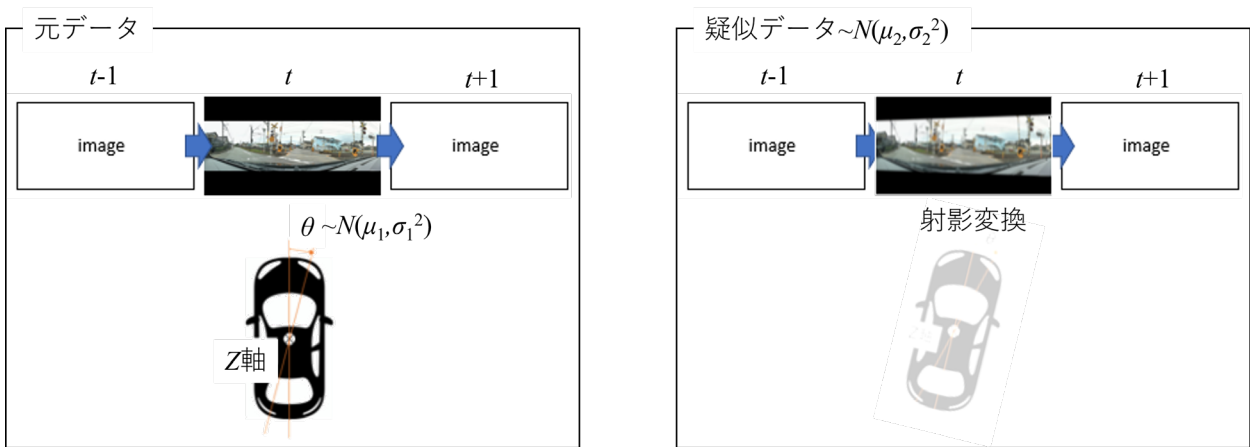


図5 車モデルを用いたオーバーサンプリング

DriveGANの学習には「VAEGAN」と「Dynamics Engine」の2つのフェーズがある。まず、VAEGANで入力された画像 x から潜在変数 z_{theme} 、 $z_{content}$ を生成している。そして、Dynamics EngineでVAEGANで得られた潜在変数 z_{theme} 、 $z_{content}$ と時系列が一致している車のスピードや車体の角速度の値 a_t から次の時間 $t+1$ の潜在変数 z_{t+1} を生成している。しかし、DriveGANのDS上では潜在変数 z_{t+1} はコントローラ操作 a_t によって変化し、取得データと同じようなスピードやステアリング操作をしないと実際の走行シーンに合わないような潜在変数 z_{t+1} が生成される可能性がある。

そこで、その問題を改善するために自動車の運動モデルを用いたオーバーサンプリングを行い、DSの生成精度を高める。自動車の運動モデルを図5に示す。 z 軸を θ 回転させたときの画像の射影変換は下記式で求められる。




図6 実験機器の配置

$$\begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \begin{pmatrix} a & b & c \\ d & e & f \\ g & h & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix}, \quad \begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \begin{pmatrix} \cos \theta & -\sin \theta & 0 \\ \sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix}$$

また、 z 軸を θ 回転させたときの角速度は下記式で求めた。 ω_t は角速度[deg/s]、 ω'_t は射影変換前の角速度 [deg/s]、 Δt は時間変化量である。

$$\omega'_t = \omega_t + \frac{\theta}{\Delta t}$$

周回データのある時間 t に対して、平均0、標準偏差 1.5 の正規分布からランダムに抽出された値 θ を適用し、データに含まれないステアリング操作した疑似データを作成する。射影変換後、画像の中心部の領域を抜き出して用いた。疑似データを元データに加え、トレーニングセットを作成する。オーバーサンプリングしたトレーニングセットで Drive GAN を学習する。これにより、様々なステアリング操作の挙動に対応した映像を生成可能になることが期待できる。

4 実験方法

4-1 目的・概要

本研究ではGANを用いて、ドライブレコーダーの映像を使ったDSの自動生成を行う。また、自動車の運動モデルを用いたオーバーサンプリング手法により作成したDSと比較する。

4-2 データの取得

運転映像は Jabra 製の 180°カメラ「PanaCast」を用いて取得した。カメラは車内前方のダッシュボードの中央付近に貼り付けた。PanaCastで撮影した動画のフレームレートは30fpsである。DS実装では8fpsに落としたデータを使用した。また、PanaCastで撮影した動画の画像のサイズは1920×1080pixelだったが、これを256×256pixelに加工し、PNGファイル形式でDriveGANに入力した。車の速度はu-blox製のGNSSレシーバー「DG



図7 走行コース

PRO1RWS」で緯度・経度の時間的変化を取得し、それを時速に変換した値を用いた。GNSS レシーバーは車の屋根の中心部に貼り付けた。ハンドルの回転角、アクセル量、車体の角速度は ATR Promotions 製の慣性計測ユニット (IMU) の TSND151 を用いて取得した。3つの IMU の設置箇所を図6に示す。3つの IMU をそれぞれハンドルの中心部、アクセル、ダッシュボードの水平な箇所に貼り付けた。また、車の速度、ハンドルの回転角、アクセル量、車体の角速度の4つのデータは JSON ファイル形式を用いて入力した。本研究では GAN を用いて、ドライブレコーダーの映像を使った DS の自動生成を行う。また、自動車の運動モデルを用いたオーバーサンプリング手法により作成した DS と比較する。

4-3 走行コース

本実験でデータを収集するために自動車で行ったコースを図7に示す。運転したコースは公立小松大学周辺を一周するコースであり、距離が約 3.5km、運転に要する時間は約6分である。このコースは道路標識が 35 個現れ、交差点を5回曲がり、踏切を2回、横断歩道を 11 回、信号を1回通過するコースとなっている。このコースの8周分のデータを集め、運転映像から約3万枚の画像を抽出した。

5 実験結果

5-1 8周分のデータでドライビングシミュレータを生成

加工されていないデータ8周分で生成した DS のシーンの例を図8に示す。データ8周分で生成した DS では道路は生成されたが、建物や自動車等のオブジェクトが混ざり合って歪んだようなシーンが生成された。また、スピードやステアリング操作を変化させても自動車の直進やカーブの挙動が全く見られず、自動車が常に停止しているようなシーンが多かった。本研究では GAN を用いて、ドライブレコーダーの映像を使った DS の自動生成を行う。また、自動車の運動モデルを用いたオーバーサンプリング手法により作成した DS と比較する。



図8 8週分のデータで生成したシーンの例

5-2 オーバーサンプリングしたデータを加え、ドライビングシミュレータを生成

オーバーサンプリングしたデータを加えて生成した DS の直進のシーンを図9、右折のシーンを図10、左折のシーンを図11に示す。オーバーサンプリングで生成した DS ではスピードやステアリング操作の変化に合った自動車の直進やカーブの挙動が見られ、実車映像と同じようなシーンが生成された。



図9 直進のシーン (上: 実車映像、下: Drive GAN)

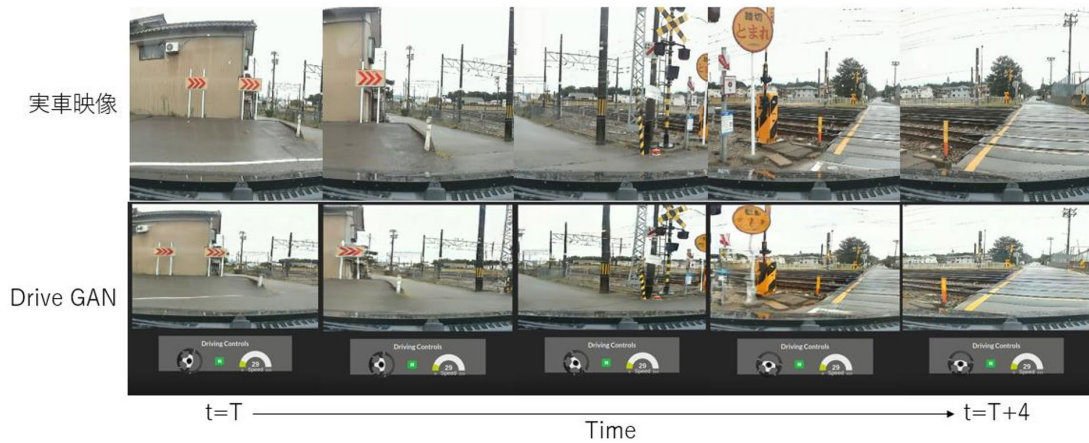


図10 右折のシーン（上：実車映像、下： Drive GAN）



図11 左折のシーン（上：実車映像、下： Drive GAN）

しかし、右左折をしている時に、建造物が歪むシーンが見られた。また、データ上で右左折していない所（交差点が無い所等）でステアリング操作を入力すると実際のコースとは異なる所での右左折のシーンにスキップした。

5-2 生成されたオブジェクトの評価

関連研究[4]に基づいて、オーバーサンプリングしたデータを加えて生成した DS で現れたオブジェクトの評価を行う。「鮮やかさ」、「形状」、「論理的整合性」の3つの項目で評価する。「鮮やかさ」は、生成されたオブジェクトが認識できる細かさであるか評価する。「形状」は、生成されたオブジェクトの形状について評価する。「論理的整合性」は、生成されたオブジェクトが、その状況に相応しいものであるかどうかについて評価する。○は、生成されたオブジェクトが、大部分で精度が高いことを示す。△は、生成されたオブジェクトが部分的には高精度だが、部分的には精度が低かったことを示す。×は、生成されたオブジェクトが、大部分で精度が低かったことを示す。

まず、一時停止標識の評価を行う。DS で生成された一時停止標識を図 12 に示す。鮮やかさは、赤色の標識は生成されたが「止まれ」の文字列が認識できなかったため、×とする。形状は、三角形の標識が確認できるため、○とする。論理的整合性は、一時停止線の隣接した所に一時停止標識が生成されているため、○とする。次に、横断歩道の評価を行う。DS で生成された横断歩道を図 13 に示す。鮮やかさは、走行車線側の横断歩道の白線は認識できるが、対向車線側の白線が認識できないため、△とする。形状は、実車映像と比較すると白線の大きさが異なっており、白線の本数も3本しか確認できないため、×とする。論理的整合性は、一時停止線の隣接した所に横断歩道が生成されているが、道路の左端から右端までに均等に白線が生成されていないため、△とする。本研究では、一定のコースを走行してデータを集めたが、DS で生成されない部分があった。また、コース上には信号機が一箇所あったが、信号機は DS では生成されなかった。



図12 生成された一時停止標識（左：実車映像、右:Drive GAN）

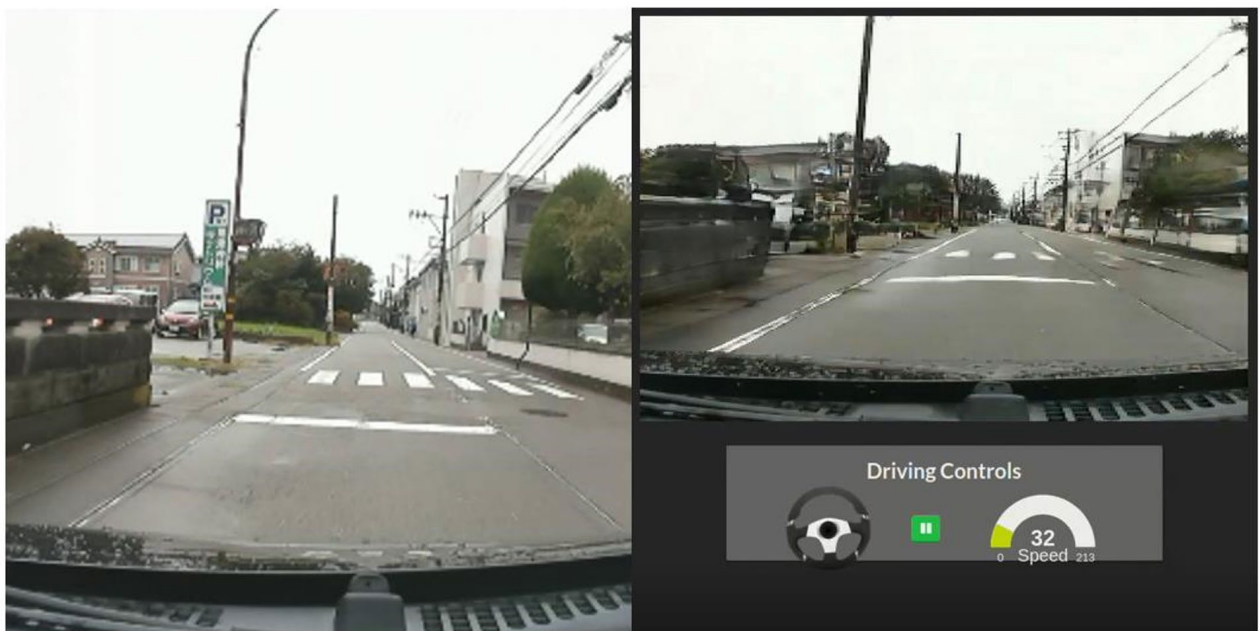



図13 生成された横断歩道（左：実車映像、右：Drive GAN）

6 考察

8周分のデータとオーバーサンプリングしたデータを加えた168周分のデータを用いた2種類のDSを生成した。8周分のデータで生成したDSでは、スピードやステアリング操作を変化させても自動車の直進やカーブ時のシーンが生成されず、自動車が停止しているシーンが多かった。一方、オーバーサンプリングしたデータを加えた168周分のデータで生成したDSではスピードやステアリング操作の変化に合った自動車の直進やカーブ時のシーンが生成され、実車映像と同様のシーンが生成された。オーバーサンプリングで生成したDSは、データ上で交差点が無い地点や右左折の操作をしていない地点でステアリング操作をするとその地点と異なる地点における右左折のシーンにスキップした。また、一時停止標識や横断歩道のオブ

ジェットの鮮やかさや形状の生成精度が部分的に低かった。それに加え、走行コース上の一部分や信号機が生成されなかった。まず、8周分のデータで生成した DS で自動車が停止しているシーンが多く生成された理由として、データのパターンが少なかったことが挙げられる。本研究では同じコースを8周したデータを使用して ドライビングシミュレータ を作成した。また、周回ごとの各地点におけるスピードやステアリング操作は同一だった。これは、自動車の運動モデルを用いたオーバーサンプリング手法により、データの パターンを増やすことで改善できた。次に、オーバーサンプリングで生成した ドライビングシミュレータ で、データ上で右左折していない所でステアリング操作を入力すると実際のコースとは異なる所での右左折のシーンにスキップした理由として、右左折のような大きなステアリング操作をしたデータが限られていたことが挙げられる。D nynamic Engine ではシーンおよびスピードとステアリング操作を基に、潜在変数を予測する。そのため、スピードとステアリング操作が異なると、潜在変数 z_{t+1} が変化し、変化した潜在変数 z_{t+1} をもとに生成器は次のシーンを生成する。また、走行コース1周につき左折を5回、右折を1回しか行われていない。ゆえに、Dynamics Engine に潜在変数 z_t と右左折のような大きなステアリング操作を入力された時、異なる所での右左折のシーンの潜在変数 z_{t+1} に遷移してしまい、実際のコースとは異なる所での右左折のシーンにスキップしたと考えられる。一時停止標識や横断歩道の生成精度が部分的に低かった理由として、入力した画像の解像度が低かったことが挙げられる。解像度が 540×540 pixel の元データから抽出した画像を、Drive GAN に入力するために解像度を 256×256 pixel に縮小した画像を用いたため、画像内のオブジェクトが粗かった。解像度を縮小した画像データを学習した上、他の標識と混じったため、オブジェクトの生成精度が低かったと考えられる。走行コース上の一部分が生成されなかった理由として、オーバーサンプリングによりデータの偏りが生じたことが挙げられる。生成された部分は一時停止で停止するシーンが多いためフレーム数が多かったことに対し、生成されなかった部分では一時停止が無く停止するシーンが無かったためフレーム数 が少なかった。このように、フレーム数の差によるデータの偏りが生じたため、走行コース上の一部分が生成されなかったと考えられる。また、信号機が生成されなかったのは、今回信号機を走行コース一周につき1回しか通過してなく、信号機はライトが青、黄、赤と点灯し変化が起きるオブジェクトで学習されにくかったからだと考えられる。また、今回は自動車の運動モデルを用いたオーバー

360度カメラ



Lidar




図13 360度カメラとLidarのデータ例

サンプリング手法により、角速度を加工したデータのパターンを増やしたが、今後はスピードを加工したデータのパターンも増やせば、様々なスピード変化に対応でき、よりロバストなドライビングシミュレータを生成可能になることが期待できる。

7 おわりに

車の運動モデルを用いたオーバーサンプリング手法を提案し、その効果を示した。今後は図 14 の Lidar および 360 度カメラを用いて、本稿の手法を適用し、より現実の空間に即したドライビングシミュレータを生成する。本助成事業の結果を発展させた内容が、科研費（基盤 B）：23H03788 に採択された。本研究にご支援を賜り厚くお礼申し上げます。

【参考文献】

- [1]Kajiwara,Y.*,Murata,E.(2022).EffectofBehavioralPrecautiononBrakingOperationofElderlyDrivers underCognitiveWorkloads.Sensors,22(7),5741.
- [2]Kajiwara,Y.*,Kimura,H.(2021).Predicting the coping skills of older drivers in the face of unexpected situation. Sensors,21(6),2099.
- [3]山本成騎, 梶原祐輔*, (2022.9.14) ,物体検出を用いた自動生成されたドライビングシミュレータのルールベース評価, 第 21 回情報科学技術フォーラム(FIT2022).
- [4]吉川晃太, 梶原祐輔*, (2022.9.13), 敵対的生成ネットワークによるドライビングシミュレータ生成時の評価指標に関する一考察, 第 21 回情報科学技術フォーラム(FIT2022).
- [5]大島大輔, 山田康右,竹之内篤,山下浩行,中野公彦,鈴木高宏,白石智良, (2015).ドライビングシミュレータに対するニーズ及び先進的関連技術に関する調査研究 67(2),8792
- [6]TrueSim | 東陽テクニカ <https://www.toyo.co.jp/mecha/products/detail/truesim.html>
- [7]Karras, T., Laine, S., & Aila, T. (2019). A style based generator architecture for generative adversarial networks. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 4401 4410)
- [8]Kim, S. W., Zhou, Y., Phillion, J ., Torralba, A., & Fidler, S. (2020). Learning to simulate dynamic environments with gamegan. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 1231 1240)
- [9] Kim, S. W., Phillion, J., Torralba, A., & Fidler, S. (2021). Drivegan: Towards a controllable high quality neural simulation. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 5820 5829).
- [10] Kingma, D. P., & Welling, M. (2013). Auto encoding Variational bayes.arXiv prepr int arXiv:1312.6114.
- [11] Hochreiter, S., & Schmidhuber, J. (1997). Long short term Memory.In Neural Computation, 9(8), (pp. 1735 1780).

〈発表資料〉

題名	掲載誌・学会名等	発表年月
敵対的生成ネットワークとオーバーサンプリングによるステアリング操作にロバストなドライビングシミュレータの生成	FIT2023 第 22 回情報科学技術フォーラム	2023 年 9 月