

# 車載画像送信量を削減するための false negative 抑圧 CNN モデルを活用した画像判別手法

石原 匠<sup>1,a)</sup> 赤間 滉星<sup>2,b)</sup> 佐藤 雅明<sup>3,c)</sup> 村井 純<sup>4</sup>

**概要:** 近年、画像認識による物体検知サービスが多数展開されており、特にモビリティ分野では衝突被害軽減ブレーキや自動運転分野などで利用されている。将来的には、こうした画像は車両単体のみでなく、遠隔地からの走行監視や指示、複数車両の情報からの交通状況把握への利用が期待されている。全ての車両から常に画像情報を送信するのはネットワーク負荷が大きく、車両側で送信の有無や優先度を判別するシステムが必要となる。本研究では、車両側で画像の有用性や重要度を評価し、必要と判断した時のみ遠隔地に送信する手法を提案する。また、ユースケースとして車両のカメラから障害物画像を集約するシステムを挙げ、「誤検知は許容しても検知漏れ (false negative) は許容しない」ポリシーで送信の判断をおこなう CNN モデルを実装し、手法の有用性に関する評価を行った。その結果、ポリシーに基づいた車両側での判断によって必要な画像を欠損することなく通信量の削減が可能であることを示した。

## An Image Discrimination Method Utilizing CNN Model to Suppress False Negative in order to Reduce the Network Traffic of In-Vehicle Cameras

### 1. はじめに

近年、画像認識を用いた物体検知サービスは日常生活の中で多数展開されている。特にモビリティ分野では多く展開されており、今まではミリ波レーダーなどのセンサを使用して行われていた予防安全技術が、ここ数年ではミリ波レーダーからの情報とステレオカメラからの情報を組み合わせて使用されることが多くなっている。

また自動運転分野では、車両に取り付けられた複数台のカメラからの情報をもとに、遠隔地の管理者が走行環境を把握・監視を行い、必要に応じて緊急停止や遠隔操縦が行われる遠隔自動運転のユースケースが想定され、福井県永

平寺町では実証実験 [1] が行われている。

今後想定されているユースケースでは、車載カメラからの情報は単一車両の情報だけではなく、複数車両間、路側に設置されたカメラなど複数箇所からの画像情報を用いて交通状況把握を行うことが期待されている。しかし、全ての車両や複数台の路側に設置されたカメラから常に高画質な画像情報を集約して、遠隔監視・操縦や交通状況把握を行うのは変動するネットワーク環境や、通信帯域への負担を考えると現実的ではない。複数車両や路側に設置されたカメラからの画像情報を用いて交通状況把握を行うには、車両、路側カメラ側で画像の有用性や重要度から、送信の有無や優先度を判別するシステムが必要となる。

本研究では、必要な画像を適切な場所に送信するようなフィルタを車両側持ち、条件に従った画像の取捨選択が可能な送信手法を提案する。本稿では、提案手法の概念実証として、車両側で軽量化した CNN モデルを使用して画像の有用性や重要度を評価し、必要と判断した時のみ遠隔地に送信する構成を実装し、精度、処理時間、通信量の観点で評価を行う。

<sup>1</sup> 慶應義塾大学総合政策学部  
Faculty of Policy Management, Keio University

<sup>2</sup> 慶應義塾大学環境情報学部  
Faculty of Environment and Information Studies, Keio University

<sup>3</sup> 慶應義塾大学政策・メディア研究科  
Graduate School of Media and Governance, Keio University

<sup>4</sup> 慶應義塾大学  
Keio University

a) takuan@sfc.wide.ad.jp

b) akakou@sfc.wide.ad.jp

c) saikawa@sfc.wide.ad.jp

## 2. 車載カメラの画像を使った協調 ITS のユースケース

SUBARU のアイサイトが日本国内での車載カメラを使用した先進安全技術の嚆矢である [2]。現在では官民共同での研究開発・普及展開が進められている [3]。また, MaaS (Mobility as a Service) などでの利活用で期待が高まっている Lv4 以上の自律運転などでは, 車載カメラの映像を用いた遠隔監視・操縦技術の研究開発も進められている。

### 2.1 車載カメラを活用した ADAS

近年運転者の安全意識の高まりから, ドライビングレコーダーを搭載する車両が増えている。また, ADAS (Advanced Driving Assistant System) と呼ばれる技術を搭載した車両も年々増加している。ADAS とは自動車がカメラやレーダーなどのセンサから周囲の情報を取得し, 警告や, 運転操作を制御する機能の総称のことである。初期の ADAS では主に超音波レーダーが用いられることが多かったが, 近年では車載したカメラを用いることが多くなっている。

ADAS は車両メーカー各社がそれぞれ設計・開発を行っており, 近年では新車搭載率が平均で 8 割を超えており [4] 普及が進んでいる。株式会社 SUBARU が販売しているアイサイトではステレオカメラ, ソナー, レーダーを使用しており, 本田技研工業株式会社が販売している Honda SENSING とトヨタ自動車株式会社が販売している Toyota Safety Sense では単眼カメラ, ミリ波レーダーを使用している。

カメラ映像を用いることで障害物を検知するだけでなく, 道路の欠損箇所を発見したり, トンネルの壁のクラックを発見する [5][6][7] ことも可能であり, 今後様々なユースケースで利活用されることが期待されている。

### 2.2 自動運転における遠隔監視・操縦

自動運転車両の研究開発, 特にドライバーレスで走行できる自律運転システムの開発は世界的にも注目されており, 日本国内でもレベル 4 以上での自律走行の研究開発が活発に行われている。

しかし, 現在日本国内では限定地域での無人自動移動サービスの実証実験には, 遠隔地に存在している「動的運転タスク作動継続が困難な場合への応答準備ができていない使用者」が, 必要に応じて監視, 操作を行うことが義務付けられており [8], 車両からリアルタイムで送られてくるカメラ映像をもとに, 遠隔地で緊急回避的に運転操作を行うことが想定されている。図 1 に遠隔自動運転のシステム構成を示す。

2021 年に福井県永平寺町で国内で初めて国土交通省によって認可を受けた, 遠隔監視・操作型の自走運行装置を備




図 1 遠隔自動運転システムの構成

えた車両を利用した実証実験 [1] が行われた。実証実験は次のような ODD (Operational Design Domain) で行われた。

- 道路区間: 京福電気鉄道永平寺線の廃線跡地, 永平寺町荒谷 志比間の約 2km
- 道路環境: 電磁誘導線と RFID による走行経路
- 気象条件: 周辺の歩行者等を検知できない強い雨や降雪による悪天候, 濃霧, 夜間等でないこと
- 交通状況: 緊急自動車が走路に存在しないこと
- 自車の速度: 自車の自動走行装置による運行速度は, 12km/h 以下
- 自車の走行状況: 自車が電磁誘導線上にあり, 車両が検知可能な磁気が存在すること, 路面が凍結するなど不安定な状況でないこと

### 2.3 ネットワークを介した画像情報共有とその課題

2.2 で述べた遠隔自動運転のシステムには規模性に関する課題がある。実際の道路環境で使用することを考えると, より多くの画像情報をネットワークを介して共有することが必要となり, 画像情報の乱れや通信遅延の増加を引き起こしてしまう。

この問題を解決する方法としては, 全ての車両に大きな計算リソースを持たせて処理を全て車両内で完結させることや, ネットワーク自体を早くするなど考えられる。しかし, 実際にシステムをスケールしていくことを考えると全ての車両に大きな計算リソースを搭載することや, 全ての画像情報をそのままネットワークを介して送信することはあまり現実的ではない。

NEC はこれらの課題に対して学習型メディア送信技術を開発した [9]。学習型メディア送信技術は, 車両から伝送される映像内の注目領域だけ自動で認識し, 注目領域以外の部分の画質は極力抑えて送信するものである。図 2 に学習型メディア送信技術の構成を示す。車両, 歩行者, 信号機, 標識などの運転判断に寄与するような物体は, 遠隔地で映像認識ができるレベルに画質を保ち, 運転の判断に関係のない植栽や建物などの画質は大きく抑えて送信することで送信データ量を削減することが可能である。

学習型メディア送信技術の検討に関する実験では, 元々約 5Mbps ほど送信していた映像データを, 必要な部分の視認性を確保しつつ, 1/10 の 500kbps に抑えられることが確認された。

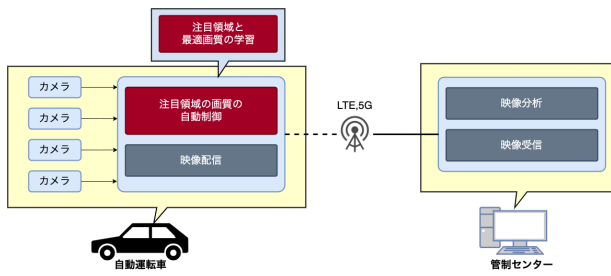


図 2 学習型メディア送信技術の構成

しかしながら、学習型メディア送信技術では注目領域が多数ある場合は送信データ量を削減できなかつたり、常にセンターと通信を行なってしまうなどの課題が残っている。

### 3. 提案

#### 3.1 提案手法: ネットワーク協調型

現在考えられている車載カメラの画像送信システムは、車両側で認識から判断まで全て行う方式、遠隔地で認識から判断まで全て行う方式、そして NEC が研究開発した学習型メディア送信技術の 3 手法が考えられる。図 3 にそれぞれの手法をモデル化したものを示す。

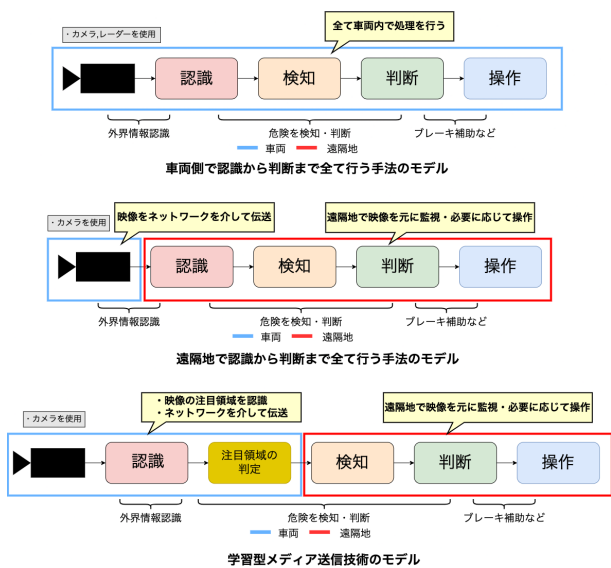


図 3 既存手法のモデル

自動運転技術や車車間、路車間通信の技術は、現在活発に研究開発が進められている [10]。将来的には図 4 で示したように、複数自動運転車両の遠隔監視・操作や車車間での通信、路車間での通信が行われることが想定されている。

今後想定されるユースケースを考えた場合、必要な画像だけを適切な場所に送信するようなフィルタを車両側で持つことができれば有用であると考えられる。その際に必要となるのは車両側で条件を設定し、その条件に従ったポリシーリングができる送信手法である。

今回は車両側で障害物を検知した時のみ送信するという




図 4 今後想定されるユースケース

ユースケースを例に、ネットワーク協調型画像送信手法を提案する。図 5 では提案手法をモデル化したものを示す。




図 5 ネットワーク協調型画像送信手法のモデル

#### 3.2 既存手法と提案手法の比較

現在考えられているモデル、及び提案手法のモデルの比較を行う。まず、車両で認知から判断・判断までを行う手法は、外界情報の認識から検知、判断までを全て同一車両内で行うため、通信遅延は発生せず即時性が必要なユースケースで有用である。一方、カメラ画像を他の周辺車両で共有して互いの死角情報の補完を行ったり、路側機によって周辺の車両情報を集約して管制制御を行うことは不可能である。

次に、遠隔地で認識から判断まで行う手法は、外界情報の認識から検知、判断までを全て遠隔地で行うため、周辺の車両情報を集約して管制制御を行うユースケースで有用である。一方、車両の周辺情報を遠隔地へ送信し続けるため、ネットワーク負荷の増加や通信遅延を引き起こしてしまう。

学習型メディア送信技術では、車両側で認識した映像に注目処理の判定を行うことで、遠隔地へ送信するデータの量を削減しネットワーク負荷や通信遅延を削減している。しかし、道路上の障害物や異常情報の収集などの、常に遠隔地に映像を送信する必要がないユースケースにおいては、無意味なデータを大量に送信してしまい収集効率が低下する。

今回提案する手法では、常に遠隔地に映像を送信する必要がないユースケースにおいて、通信量を削減し必要なデータのみを遠隔地に届けるために、車両側で検知、送信判断まで行う。しかし、本手法のスケールアウトを考えた際に、全

ての車両に大きな計算リソースを搭載することは現実的ではなく、小さい計算リソース上でも利用が可能な画像認識モデルを使用する必要がある。誤検知は許容し、見落としは許容しないようにチューニングし軽量化したモデルを使用すれば、上記のような問題も解決できると考えられる。

## 4. 設計

今回は提案手法が活きる活用事例として、道路上の障害物の画像を遠隔地で集約する用途を考える。図6にシステム全体の構成を示す。

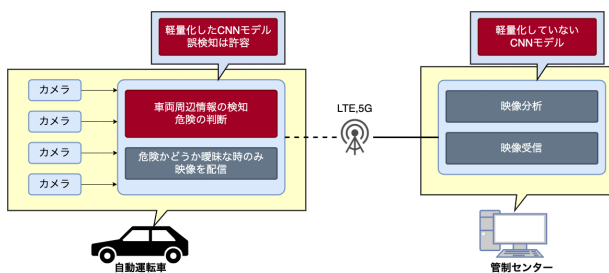


図6 ネットワーク協調型画像送信手法の構成

今回の設計においてネットワーク協調型画像送信手法の要件は以下の通りとした。

- 車両では軽量化したモデルを使用：処理速度を上げて実時間性を持たせるため
- false negative を許容しないフィルターを使用：見落としを防止するため

## 5. 実装

今回は障害物を人間に限定し評価実験を行うこととして、遠隔地で利用するCNNモデルと車両側で利用するCNNモデルの2種類を実装する。

### 5.1 CNNモデル

分類器の作成には、画像の深層学習に多く使われるCNN(Convolutional Neural Network)[11]を使用する。CNNは通常のニューラルネットワークに「畳み込み層」と「プーリング層」と呼ばれる層を学習に使用したものである。図7にCNNの典型的なネットワーク構造を示す。

#### 5.1.1 畳み込み層

畳み込み層では、データの特徴を際立たせる役割を果たしている。従来のニューラルネットワークでは元画像全体をそのまま結合し学習させることが基本だったが、画像全体から対象の特徴を正確に捉えることは難しく、精度が向上しないことが多かった。そのため、CNNでは画像全体から対象の特徴を取り出して学習することを目的として畳み込み層が導入された。

#### 5.1.2 プーリング層

プーリング層では、画像の詳細情報を削除する役割を果たしている。入力画像サイズのまま、出力まで同解像度でネットワークを組んでしまうと、学習に使用するメモリや計算量が膨大になってしまう。そこで、出力層に近づくにつれて解像度を低くさせる目的としてプーリング層が導入された。

### 5.2 遠隔地で利用するCNNモデル

遠隔地で利用するCNNモデルは教師データとして、

- 人間を含む道路画像 1000枚
- 人間を含まない道路画像 1000枚

をWebクローラのミニフレームワークであるicrawler[12]を使用し、Google画像検索、Bing画像検索、duckduckgo画像検索からスクレイピングして取得した。

また教師データの水増しを行うため、オープンソースニューラルネットワークライブラリであるkeras[13]のImageDataGeneratorを使用して、画像の反転などを行い1000枚ずつ水増しを行なった。

### 5.3 車両側で利用するCNNモデル

車両側で利用するCNNモデルは、遠隔地で利用するCNNモデルを誤検知は許容するが見落としは許容しないようにパラメータをチューニングして軽量化したモデルである。具体的には、

- 学習の開始時にプーリングを行い画像の解像度を下げる
- プーリング時の圧縮率を大きくする
- 畳み込み時のフィルタの目を大きくする

の3点を行い、誤検知は許容するが見落としは許容しない条件を満たすモデルが作成されるまでチューニングを行った。

## 6. 評価実験

提案手法が有用であるか概念実証を行うために、モデルの実行にかかる時間と通信のRTT、遠隔地に送信したデータ量の観点で以下3手法の比較を行った。

- 提案手法
- 全て車両で処理を行う場合
- 全て遠隔地で処理を行う場合

それぞれの手法で、教師データとは別の人間を含む画像50枚と含まない画像50枚の合計100枚の画像を入力データとして読み込ませ、処理に要した時間、通信量を計測した。評価実験の構成は図8に示す。

### 6.1 評価実験環境

評価実験は以下のような環境で行なった。提案手法に関しては様々な用途や予算を想定して車両側でrasberry piとMacBook Proの計算リソースの異なるデバイスを用い



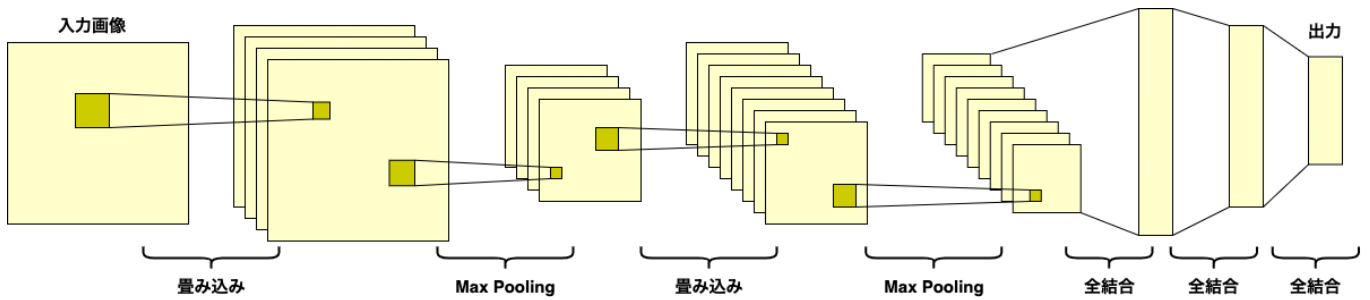


図 7 CNN の典型的なネットワーク構造




図 8 評価実験の構成

て実験を行った. 表 1 に実験に用いたデバイスを示した.

表 1 評価実験に用いたデバイス

	車両側 1	車両側 2	遠隔地側
OS	raspbian	macOS Big Sur	Ubuntu 18.04
RAM	4GB	64GB	8GB
CPU	BCM2711	Intel Core i9	Intel Xeon Silver
GPU	1.8GHz	1.8GHz	Quadro P6000 × 2
python	3.8.1	3.8.1	3.8.1
tensorflow	2.6.2	2.5.0	2.6.2
keras	2.2.4	42.2.4	2.7.0

### 6.1.1 入力データ

実験に用いた入力データは以下ようになった.

- jpeg 画像 100 枚
- 3800KB
- 人間: 50 枚
- その他: 50 枚

### 6.2 モデルの評価

作成した 2 種類の CNN モデルの精度の確認を行った. 表 2 に遠隔地で利用する CNN モデルの精度を, 表 3 に車両側で利用する軽量化した CNN モデルの精度を示した.

表 2 遠隔地で利用する CNN モデルの精度

	人間 50 枚	人間なし 50 枚
あり	50	2
なし	0	48

車両側で利用する CNN モデルでは誤検知の数は増加してしまいましたが見落としは一件もなく, 誤検知は許容するが見落としは許容しない条件を満たすモデルを構築することができた.

表 3 車両側で利用する CNN モデルの精度

	人間 50 枚	人間なし 50 枚
あり	50	7
なし	0	43

### 6.3 処理時間に関する評価

提案手法と全て車両で処理した場合, 全て遠隔地で処理した場合の処理時間について 10 回実験を行い平均値で比較を行なった. 提案手法で raspberry pi 4 を用いた場合は 1,306msec, 提案手法で MacBook Pro を用いた場合は 416msec, 全て車両側で処理した場合は 1,880msec, 全て遠隔地で処理した場合は 206msec の時間を要した. 提案手法で要した時間の内訳は, Raspberry pi 4 を用いた場合では車両側で 1,100msec, 遠隔地で 180msec, 通信で 26msec で, 提案手法で要した時間の内訳は, MacBook Pro を用いた場合では車両側で 210msec, 遠隔地で 180msec, 通信で 26msec で, 全て遠隔地で処理した場合に要した時間の内訳は, 遠隔地で 180msec, 通信で 26msec であった.

図 9 は処理時間に関する評価実験の結果を横棒グラフで示したものである.




図 9 処理時間に関する評価

全て車両側で処理した場合に比べて提案手法では処理全体に要する時間を短縮することができた.

### 6.4 送信データ量に関する評価

提案手法と全て車両で処理した場合, 全て遠隔地で処理した場合の送信データ量に関する比較を行なった. 提案手法では 1,878KB, 全て車両側で処理した場合は通信を行っていないため 0KB, 全て遠隔地で処理した場合は

3,800KB となった。

図 10 は送信データ量に関する評価実験の結果を横棒グラフで示したものである。

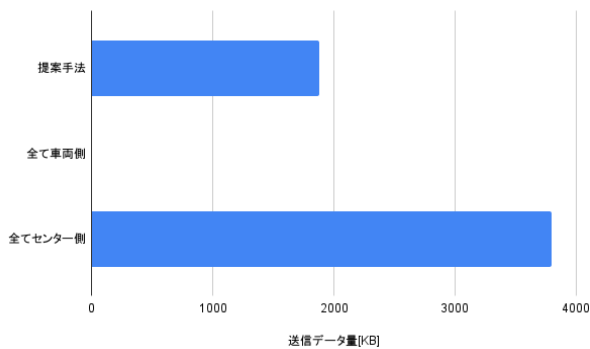


図 10 送信データ量に関する評価

全て遠隔地で処理した場合に比べて提案手法では送信データ量を半分以上削減することができた。

### 6.5 実際の車載映像を用いた評価

今回上記の評価実験では web 上から取得した映像を用いて実験を行った。実際の車載映像を用いてモデルの動作の確認を行い、実環境での有用性を確認するために、実際のドライブレコーダーの映像を用いてモデルの評価も行った。図 11 は実際のドライブレコーダーの映像の一部である。



検知成功した写真



見落としした写真

図 11 実際のドライブレコーダー映像の一部

実際の車両データを用いた場合でも、日中のはっきりと写った映像では見落としなく精度を保ったまま検知を行うことができたが、逆光や夕方の暗めの画像では見落としがあり、精度を保つことができなかった。誤検知に関しても 6.2 の実験時よりも多く発生した。

### 6.6 考察

評価実験の結果から、提案手法は処理時間を抑えつつ送信データ量を削減できるバランスの取れた手法であることが明らかになった。処理時間の短縮に関してはモデルのチューニングで今回行わなかった量子化などを別の手法と取り入れていくことで、さらに削減できるのではないかと考えられる。また、実際の車両での利用を考えた場合はモデル構築の教師データを実際の車載映像を用いる必要があることが明らかになった。

## 7. おわりに

本稿では車両側で障害物を検知した時のみ送信するというユースケースに着目して、ネットワーク協調型画像送信手法を提案して、提案手法と全て車両側で処理する場合、全て遠隔地で処理する場合における処理時間と送信データ量に関する評価を行なった。

その結果、提案手法では全て車両側で処理する場合に比べて、処理時間を短縮することができた。全て遠隔地で処理する場合に比べて、時間は 5 倍ほど多く要してしまったが、送信データ量は半分以上に抑えることができた。

しかしながら、今回のモデルの教師データには Web 上から取得した映像を用いたため、実際の車載映像を用いた場合には false-negative が発生することが分かっており、実用に際してはさらなる改良とモデルの再構築が必要である。

今後は、提案手法をより実世界で利用できるものに近づけていくために、実際の車載カメラからのデータを教師データとして利用した CNN モデルの構築や、学習モデルの精度を保ったままより軽量化できる方法の検討・実装、車両側で認識した情報を必要な場所に送信する技術の検討・実装などを行なっていく予定である。

### 参考文献

- [1] 国土交通省：永平寺ラストマイル自動運転車の認可，入手先 (<https://www.mlit.go.jp/report/press/content/001391990.pdf>)
- [2] 碓井茂夫，野村直樹，熊谷光，関根浩史：運輸支援システム“アイサイト”の事故低減への取り組み，日本 AEM 学会誌，Vol.25，No.4，pp.383-389，2017，入手先 ([https://www.jstage.jst.go.jp/article/jsaem/25/4/25\\_383/\\_pdf/-char/en](https://www.jstage.jst.go.jp/article/jsaem/25/4/25_383/_pdf/-char/en))，
- [3] 国土交通省自動車交通局 先進安全自動車推進検討会：先進安全自動車推進計画 報告書，入手先 (<https://www.mlit.go.jp/jidosha/anzen/01asv/data/asv3seikahoukokusyocorrection.pdf>)
- [4] 内閣府：先端技術について，入手先

- ([https://www8.cao.go.jp/koutu/taisaku/r01kou\\_haku/zenbun/genkyo/topics/topic\\_11.html](https://www8.cao.go.jp/koutu/taisaku/r01kou_haku/zenbun/genkyo/topics/topic_11.html)), (2022-02-14)
- [5] Hiroya Maeda, Yoshihide Sekimoto, Toshikazu Seto, Takehiro Kashiya, and Hiroshi Omata: Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images, Vol. 33, pp.1127-1141. Wiley Online Library, 2018. 入手先 ([https://www.researchgate.net/publication/326087983\\_Road\\_Damage\\_Detection\\_and\\_Classification\\_Using\\_Deep\\_Neural\\_Networks\\_with\\_Smartphone\\_Images\\_Road\\_damage\\_detection\\_and\\_classification](https://www.researchgate.net/publication/326087983_Road_Damage_Detection_and_Classification_Using_Deep_Neural_Networks_with_Smartphone_Images_Road_damage_detection_and_classification))
- [6] Abdullah Alfarrarjeh, Dweep Trivedi, Seon Ho Kim, and Cyrus Shahabi: deep learning approach for road damage detection from smartphone images. In 2018 IEEE International Conference on Big Data (Big Data), pp. 5201-5204. IEEE, 2018. 入手先 ([https://infolab.usc.edu/DocsDemos/IEEE\\_BigData\\_RoadDamageDetection.pdf](https://infolab.usc.edu/DocsDemos/IEEE_BigData_RoadDamageDetection.pdf))
- [7] Makoto Kawano, Kazuhiro Mikami, Satoshi Yokoyama, Takuro Yonezawa, and Jin Nakazawa: Road marking blur detection with drive recorder. In 2017 IEEE International Conference on Big Data (Big Data), pp. 4092-4097. IEEE, 2017. 入手先 (<https://ieeexplore.ieee.org/document/8258427>)
- [8] 官民 ITS 構想・ロードマップ 2020: 高度情報通信ネットワーク社会推進戦略本部・官民データ活用推進戦略会議 入手先 ([https://www.kantei.go.jp/jp/singi/it2/kettei/pdf/20200715/2020\\_roadmap.pdf](https://www.kantei.go.jp/jp/singi/it2/kettei/pdf/20200715/2020_roadmap.pdf)), (2022.02.07)
- [9] YANASE Kazuhiro, SHIOZAKI Masashi, MIZUKOSHI Yasuhiro, IWAI Takanori, NIHEI Koichi, NISHIMURA Shoji: Vehicle Interior/Exterior Monitoring Solution for Safe Transportation of People and Goods, NEC Technical Journal, Vol.15, No.1, p73-77, 2019.
- [10] SIP 自動運転システム実用化 WG: SIP 協調型自動運転ユースケース, 入手先 (<https://www.sip-adus.go.jp/rd/rddata/usecase.pdf>),
- [11] 中山英樹: 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習, 入手先 ([http://www.nlab.ci.i.u-tokyo.ac.jp/pdf/CNN\\_survey.pdf](http://www.nlab.ci.i.u-tokyo.ac.jp/pdf/CNN_survey.pdf))
- [12] icrawler: 入手先 (<https://github.com/helloklock/icrawler>), (2022.02.07)
- [13] keras: 入手先 (<https://github.com/keras-team/keras>), (2022.02.07)