



Technical
Survey

技術解説

AI ドラレコを支える技術

～DRIVE CHART を例に～

本記事関連動画を
ホームページで公開中!
www.ite.or.jp

菊地進一[†], 内田祐介[†]

自動車の交通事故による被害は減少傾向にあるものの引き続き大きな社会課題であり、交通事故につながる可能性のあるリスク運転を自動的に検出する、AI機能を備えたドライブレコーダ (AIドラレコ) が注目を集めている。本稿では、リスク運転の自動検出の取り組みを広く紹介しつつ、実サービスを例にAIドラレコを実現するための技術要素を解説する。

キーワード：交通事故削減、ドライブレコーダ、AIドラレコ、リスク運転、深層学習、物体検出

1. まえがき

自動車の交通事故による被害は減少傾向にあるものの引き続き大きな社会課題である。これまで交通事故の分析とその対策には、発生状況や違反状況などの観点で要因を分析する手法が用いられてきた。交通事故や交通死亡事故は社会に与える影響が大きいことから、網羅的かつ長期間にわたる交通統計データが記録されている。主な区分としては、エリア (市区町村、商業地・非商業地) に加え、ドライバーの年齢、事故種類 (対人・対物)、時間 (昼夜・曜日)、道路形状 (交差点・単路)、運転操作 (直進、右左折)、違反状況 (速度超過、停止違反、脇見運転) などが挙げられ、これらの詳細なクロス集計の結果が提供されている¹⁾。これらは公共交通政策のように一般的な傾向を調査する際には有効であるが、交通事故は個々のドライバーにとって一生に限られた数しか発生しない稀な事象であり、自分自身が交通事故を発生させないために具体的にどのような行動変容が必要とされているのかを理解することは難しい。また、個人の運転傾向を分析する手法として、Driving Behavior Questionnaire (DBQ) のような質問紙法がある。これはヒューマンエラーの4因子である lapse (失念)、mistake (判断・操作ミス)、violation (過失) を用いて運転傾向を評価するもので、いろいろな国で用いられている²⁾。このように個人の運転傾向と事故リスクの関係をj知することはできるものの、やはり具体的な運転行動と比べると抽象度が高く、日常の運転で注意すべき点を知ることは難しい。そこで交通事故削減の取り組みとして、日常の運転データから、交通事故につながるようなリスク運転を自動で検出してフィードバックをするという、いわばオーダーメイド型の対策を提供する取り組みが増えつつある^{3)～5)}。これは近年の

ビッグデータ解析の文脈と同じように、大量の個人データと集団データを収集・分析することで実現される。検出対象であるリスク運転は、交通事故そのものに比べて発生回数が多いため、行動変容につながりやすいと言える。

10年ほど前から、損害保険会社によって試験的に導入されているテレマティクス保険と呼ばれる取り組みは、このような個人の運転傾向に着目したものである。被保険者は契約車両に車両運動センサを取り付けることで事故発生リスクの算出に協力し、保険料のディスカウントを得るという仕組みになっている⁶⁾。テレマティクス保険は実際に事故が発生しなくても事故リスクが算出されてしまうため、運転に自信のないドライバーの事故削減というよりは、運転のうまいドライバーに対して、より安全な運転を促すスキームと言える。一方で近年話題となっており、今回紹介するAI機能を備えたドライブレコーダ (AIドラレコ) は、交通事故につながる可能性のあるリスク運転を自動的に検出する、まさにオーダーメイド型のリスク運転削減を目指したものである。

後述するように、AIドラレコの一般的な構成は車両運動センサや車載カメラ、地図情報をインプットとして用いる。個人差を検証するためには大量のセンサデータや動画の解析が必要となり、大規模分散処理の仕組みが重要となる。車載カメラに関しては、単に車外環境やドライバーの様子を認識するだけでなく、その他のセンサと組み合わせることで車両運動の推定精度を向上させることができる。さらにドライバーの理解を助けるためのコンテンツとしても使われる。例えば、運輸事業に従事するドライバー625人の2年間を対象に行われた大規模なコーチングの検証において、抽出された自身のリスク運転の動画を用いたフィードバックメカニズムが事故削減に有効であったことが示されている⁷⁾。すなわちAIドラレコでは、従来からのセンサ解析のみならず、動画からのシーン検出、ハイライト動画の作成が重要な要素技術となっており、コンピュータビジョンに

[†] 株式会社 Mobility Technologies

"Technologies for AI Dashcam: DRIVE CHART" by Shinichi Kikuchi and Yusuke Uchida (Mobility Technologies Co., Ltd., Tokyo)

おける学術的な取り組みと社会実装に近い関係にあるのも特徴の一つである。以降では、これまでに行われてきたリスク運転の自動検出の取り組みについて紹介し、次にAIドラレコに使用されている技術に関してDRIVE CHARTを事例として紹介していく。

2. リスク運転の検出

Johnsonらはスマートフォンを後付けのセンサとして用いることで、車両運動の推定を行い、リスク運転の検出を行った⁸⁾。MIROADと呼ばれるこのシステムは、加速度センサ、角速度センサ、地磁気センサ、GPS、動画等を入力とし、急加速、急停止、交差点での急ハンドル、急な車線逸脱といった基本的なリスク運転を検出している。Castignaniらは運転に大きな影響を与える天気や時間帯といった文脈情報を加味して運転スコアを算出するSenseFleetというシステムを考案した⁹⁾。文脈情報の考慮にはファジー推論が用いられ、アクセル・ブレーキの変化量(加速度の差分)、ハンドルの変化量(角速度)を用いた運転評価を補正している。10人の被験者に決まったルートを走行してもらい、そのパラメータの調整を行った。実際に頻繁に急加速・急減速を繰り返すようなドライバは交通事故や交通違反が多いことが知られている。

Händelらは同じくスマートフォンを用い、テレマティクス保険を実現するために技術的な障害となっているセンサデータのノイズ除去の課題に取り組み、最終的に自動車保険における共通因子(Figure of Merits: FoM)を同定した¹⁰⁾。具体的には、急加速、急減速、速度違反(絶対速度、相対速度)、不要な加減速、車線逸脱、急ハンドル、燃費の8因子からなる。これはさまざまな文脈での観測安定性、保険数理的な関連性、ドライバのリスク運転削減への影響といったものを考慮したものである。運転評価に大きな変動を与えてしまう運転距離、時間帯、場所といったバリエーションの組み合わせに対して、広く適用可能な保険システムとなっている。また個々のリスク運転の検出精度向上にも力を注いでおり、車両重心とトルクの量から、スリップや横転につながる急ハンドルの量を理論的に計算し、カルマンフィルタによって走行時の値を推定する系などを構築している¹¹⁾。If P&C Insurance社はこれらの技術を用いて、2013年にスウェーデンでテレマティクス保険のパイロット版「If SafeDrive」の提供を行った。このキャンペーンには、約1,000人のドライバが参加し、リスク運転の情報もリアルタイムにフィードバックされた。合計の走行データは4,500時間、25万kmからなり、大規模なテレマティクス保険としては初の取り組みである^{10) 12)}。このような取り組みに関わらず、スマートフォンによるリスク運転の検出が普及しているとは言えないのは、精度に対する課題というよりも、利用する機種や車種の違い、マウント位置の違い、バッテリー消費や高熱の発生など、運用上の課題によると

ころが大きい^{13) 14)}。

漫然運転や脇見運転の検出では機械学習を用いた映像解析が重要な役割を占める。2値分類(不注意かどうか)の枠組みで学習を行うケースもあるが、マルチクラス分類(認知的な不注意、脇見運転、スマートフォンの操作、オーディオ機器の操作など)として学習することも多い。汎用的なカメラを用いた手法として、例えば次のような事例が存在する¹⁵⁾。Liらはドライバ映像を取得する内向きカメラと車両センサを用いて、顔向き、開閉度、車速、操舵量、ブレーキ量を変数としてマルチクラス分類問題として学習を行った¹⁶⁾。また車外映像を取得する外向きカメラと車両センサを用いて、車線逸脱量と操舵量という車線維持に関する変数に着目した検出も行われた。Masoodらは内向きカメラからドライバの3次元姿勢を推定し、汎用的なドライバの行動認識を行うことでマルチクラス分類を解いている¹⁷⁾。居眠り検知はドライバの内的状態の変化を、瞬目時間(閉眼時間)、瞬目回数(開閉周期)、眼の開度、閉眼率などの眼に関する情報を抽出して行われる。中でもpercent eye closure (PERCLOS、閉眼時間割合)は運転時の眠気評価に最もよく使われている指標である。これは居眠り運転の兆候として瞬目の閉眼時間が長くなるという生理学的な知見を運転時の指標に応用したものである¹⁸⁾。

車両センサを用いたリスク運転の検出に加え、道路情報(一時停止線、制限速度など)を利用することで交通違反の検出も可能となる。GPSから得られる走行軌跡をもとに、道路ネットワーク(道路距離、道路曲率、道路方位)や道路属性(制限速度、道路等級)を拘束条件として道路情報を紐付ける技術としてマップマッチングが存在する^{19) 20)}。マップマッチングは交通違反の検出に有効ではあるが技術的課題も多い。例えば、あるGPS軌跡において候補道路の数が多くなるほど正確なマッチングが難しくなるため、都市部や交差点付近のような道路密度の高いエリアでは間違いが生じやすくなる¹⁹⁾。同様に道路情報が存在しない私有地ではどのような走行経路を推定しても間違いになってしまう。また走行経路が必ずしも地図情報と一致しないこと、その地図の更新も数ヵ月おきであり、実際の走行状況と異なるケースがあることなどが課題として挙げられる²¹⁾。

アメリカで行われた100-Car Naturalistic Studyとその後継的位置付けであるSecond Strategic Highway Research Program (SHRP2)は最もよく用いられている運転オープンデータである^{22) 23)}。SHRP2は約3,500人(16歳～98歳)の運転を1年以上にわたって追跡したもので世界最大規模の走行記録(320万時間、8,000万km)が提供されている。データには車両センサ情報、動画(前方、後方、ドライバおよび側方、助手席および側方)、健康状態など当日のドライバ情報などが記録されている。現在36,000件の危険イベント(交通事故、ニアミス、ヒヤリ・ハット)とその環境情報がアノテーションされている。約6%が高リスク群、

12%が中リスク群、82%が低リスク群というドライバ分布であった。また、Roadway Information Database (RID) という電子地図とそのマップマッチング結果も提供されている。このようなデータの整備によって、世界的に運転傾向の分析が進んだことを契機に、自然運転データ分析 (Naturalistic Driving Study: NDS) と呼ばれる運転ビッグデータ解析の分野が盛んになりつつある。ヨーロッパ全域においても euroFOT などの大規模に自然運転データを収集する取り組みが存在するが、これまで日本ではこの規模のデータの収集・解析は行われていない。

欧米における自然運転データの収集と解析は、政府や学術機関を中心に行われているのが特徴と言える。すなわち運転が仕事ではない市民ドライバを含めた社会全体での事故削減に焦点が当てられている。そのためデータも大規模で公共性が高く運用されている。前述のテレマティクス保険も同様に市民ドライバ向けである。一方で、日本にはそのような大規模な公共データベースはないものの、職業ドライバを対象とした運転データの蓄積が先行している。運輸事業者には運輸安全マネジメントという国の枠組みによって、安全運転のコーチングとその効果分析がそもそも日常の業務に含まれている点が、市民ドライバ向けとの大きな違いである。実際に公共交通サービスや物流のサービスは社会インフラでありながら、少しの油断が人身事故につながる恐れがある。ドライバの高齢化も進んできており、AIドラレコへの期待は高まっていると言える。次章以降では大規模な実サービスとして商用化されているAIドラレコ機能および技術要素をDRIVE CHARTを事例として解説する。

3. DRIVE CHART 概要

われわれが提供している交通事故削減支援を行うAIドラレコサービスであるDRIVE CHARTを例に、AIドラレコ

を支える技術について解説する。

DRIVE CHARTは、走行中の映像やセンサデータを解析し、交通事故につながる可能性のある危険な運転行動をリスク運転として検出し、ドライバと管理者へ提示するレポート機能を提供している。現在このリスク運転としては、脇見運転、車間距離不足、一時不停止、速度超過、急ハンドル、急加速、急減速、急後退の8項目が存在する。また、リアルタイムにドライバへ注意喚起を行う機能として車間距離警報、衝突警報、脇見警報が、管理者に事故発生の可能性を通知する機能として衝撃検知が存在する。

DRIVE CHARTでは、大規模かつリアルタイムなセンサおよび映像データの収集・解析に対応するため、Amazon Web Services (AWS) 上にスケーラブルなシステムを構築している²⁴⁾。

4. DRIVE CHARTを支えるAI技術

DRIVE CHARTにおけるAI処理を紹介しながら、AIドラレコで必要となる技術を概観する。

図1は、DRIVE CHARTにおける処理のうち、AI技術が関連する部分の処理の流れを簡略化したものである。DRIVE CHARTにおけるAI処理は、主にエッジデバイスであるAIドラレコにおけるエッジAI処理と、レポート機能を提供するサーバにおけるサーバ処理に分けられる。以下ではそれぞれの処理について説明する。

4.1 エッジAI処理

AIドラレコでは、ドライバ映像を取得する内向きカメラ、車外映像を取得する外向きカメラ、加速度センサ、角速度センサ、GPSセンサ等の情報を取得する。エッジAI処理では、図2のように内向き・外向きカメラの映像を深層学習モデルで認識し、認識結果を他のセンサ情報とともにサーバへアップロードする。以下ではエッジAI処理で利用されている深層学習モデルを紹介する。




図1 DRIVE CHARTにAI処理の概要




図2 内向きカメラ (左) と外向きカメラ (右) の映像

車両検知モデル：外向きカメラ映像を入力として、車両や歩行者などの物体を検知する。計算量の観点からYOLO²⁵⁾に代表されるsingle shot物体検知モデルアーキテクチャを採用し、対象物体の入力映像中での座標、クラス、信頼度を出力する。この情報は主に車間距離不足を検知するために利用される。

レーン認識モデル：外向きカメラ映像を入力として、人物姿勢推定で利用されるheatmapベースの手法²⁶⁾を用いてレーン位置をキーポイントの集合として認識することで、道路上に存在するレーン情報を検知する。

ドライバ検知モデル：車両検知モデルと同様にsingle shot物体検知モデルとして、ドライバの顔領域を検知する。このモデルでは、顔領域を検知するだけでなく、顔ランドマークの検知、顔ランドマークが他の物体に隠されているかどうかのオクルージョン判定、ドライバがサングラスやマスクを着用しているか等の属性認識を同時に行うモデルとなっている。このモデルの出力結果は、脇見検知や顔認証で利用される。

ドライバ行動認識モデル：前述のドライバ検知モデルで検知された各時刻の顔領域から畳み込みニューラルネットワーク (CNN) を用いて特徴抽出を行い、その特徴の時系列データをLong Short-Term Memory (LSTM) に入力する²⁷⁾ことで時系列情報を考慮したドライバの行動認識を実現する。現在は後述の脇見警報にこの出力結果が利用されている。

エッジデバイスでは、複数の処理を限られた計算資源で実行しなければならない。このため、特に深層学習モデルは、なるべく計算量の小さなモデルを利用することが望ましい。そのような軽量モデルを実現するための手法は多く存在する²⁸⁾が、特にseparable convと呼ばれる畳み込みを利用した、MobileNet²⁹⁾やEfficientNet³⁰⁾等の軽量のCNNをベースとした上で、枝刈り (pruning) と呼ばれる、畳み

込み層のチャンネル数を削減する手法を適用することが現実的である。上記のモデルもそのような軽量化を行うことで、エッジデバイスでの複数モデルの動作を実現している。

DRIVE CHARTでは、レポート機能だけではなく、リアルタイムにドライバーに注意喚起を行う機能として、車間距離警報、衝突警報、脇見警報を提供しており、これらはエッジAI処理の中で検出が行われる。また、管理者に事故発生の可能性を通知する機能として衝撃検知が存在する。

車間距離警報：車間距離警報は車間時間 Time Headway (THW) が閾値以下となっている状態が一定時間以上継続した場合に注意喚起を行う。THWとは、前方車両との距離を自車走行速度で割った値であり、前方車両の現在位置に自車が到達するまでの時間を示している。前方車両との距離は、車両検出モデルにより検出された物体のy座標と、外向きカメラ映像中の消失点のy座標から算出される。これは、物体が道路平面に存在する場合、「画像中のy座標と消失点のy座標との距離」が実際の距離と反比例する関係性にあることに基づいており、予め係数をキャリブレーションにより求めておくことで実際の距離が算出可能となる。

衝突警報：衝突警報は前方物体との衝突までの時間 Time to Collision (TTC) が閾値以下となった場合に注意喚起を行う。TTCは前方車両との距離を速度の差 (相対速度) で割ることで算出される。前方車両との距離は車間距離警報と同様のロジックで算出される。前方車両との相対速度は、車両検出モデルにより検出された前方車両をトラッキングすることで算出される。

脇見警報：脇見警報は、脇見状態を検出するように学習させたドライバ行動認識モデルの出力を利用して注意喚起を行う。

衝撃検知：加速度センサの情報をもとに、閾値以上の衝撃を受けた場合に事故の可能性があるとして検知を行う。

4.2 サーバAI処理

本節では、エッジデバイスからサーバに送られてきた各種センサデータおよび映像解析結果をもとに行われるリスク運転検出処理について概説する。DRIVE CHARTの特徴として、エッジデバイスでの解析結果だけでは信頼性が足りないと判断されるケースにおいて、エッジデバイスから自動的に映像を取得し、サーバで追加の映像解析を行う汎用的な仕組みが存在することが挙げられる。例えば、車間距離不足、脇見、一時不停止、急後退でこの仕組みが利用されている。

マップマッチング：2章で解説したとおり、地図データを活用してリスク運転を検出するためには、GPS軌跡から実際の走行経路を推測するマップマッチングが不可欠となる。DRIVE CHARTでは、内製のマップマッチングエンジンを開発し、データ構造を最適化することで、全国規模の道路ネットワーク上でのマップマッチングを実現している³¹⁾。

車間距離不足：車間距離不足は、基本的には車間距離警報と同等のロジックで検出を行う³²⁾。警報と異なり、レポートのためのリスク検出はリアルタイム性が求められないため、エッジAI処理の結果をもとにまずはリスク候補を検出し、追加の映像解析機能を用いてサーバにてより高性能な深層学習モデルを動作させることにより高精度な検出を実現している。具体的には、車間距離警報のロジックに加えて、直接的に対象物体との距離を推定するモデル³³⁾の出力や、車両幅の情報などをベースに、総合的に判断を行っている。

脇見：脇見は、脇見警報のためのドライバ行動認識モデルの出力から候補を絞り、追加の映像解析機能を用いてよりサイズの大きなCNNとBidirectional LSTM (BiLSTM)を組み合わせた行動認識モデルにより最終的な検出を行う³⁴⁾。

一時不停止：マップマッチング結果をもとに、地図データベースに一時停止情報のある交差点を通過したことを検出し、一時停止線の前後の最低車速が閾値よりも大きい場合に一時不停止として検出を行う。この際、追加の映像解析機能を用いて、物体検出モデルによる実際の走行経路に一時停止標識が存在することの確認と、映像ベースの車速推定モデルによる停止判定を行うことで精度を担保している。

急後退：1段階目の処理として、GPSセンサ、加速度センサ、角速度センサ、およびマップマッチング結果から、後退が発生した可能性がある候補時間を絞り込む。この際、GPSセンサのみでは車両の進行方向を加味した前進、後退の速度を観測することが難しいため、角速度センサを合わせて用いることで車両の移動を前進、後退に分離する。2段階目の処理では、1段階目の処理で得られた急後退候補に対して、追加の映像解析機能を用いて、映像ベースの車速推定モデルにより精度の高い後退行動を検出。スイッチバック時間と呼ぶ前進停止時刻から後退開始時刻までの間隔が定められた基準より短い場合に急後退として検出する。

急ハンドル、急加速、急減速：これらのリスク運転検出には、主に加速度センサの情報を利用する。具体的には、急ハンドルは、車両前方向に対して左右方向の加速度の絶対値が閾値以上となった場合に検出される。急加速および急減速は、それぞれ車両前方向および車両後方向の加速度が閾値以上となった場合に検出される。また、坂道にて発生する加速度へのバイアスや、悪路における振動の影響を除去する処理を行うことで、誤検出の削減を実現している。

速度超過：速度超過は、マップマッチングにより求められた走行経路から制限速度情報を取得し、GPSから算出される走行速度が制限速度より閾値以上超過している場合に検出する。

顔認証：各走行データとドライバを紐付けるため、DRIVE CHARTでは顔認証技術によりドライバの特定を行っている。顔方向やマスクの有無等によらない、自然な運転状態での認証を実現するため、大量の実走行映像から日々学習データをアップデートしながら顔認証モデルの学習を行っている。

5. むすび

本稿では、交通事故を削減する一つ的手段として注目されている、AI機能を備えたドライブレコーダについて、これまでに行われてきたリスク運転の自動検出の取り組みを紹介しつつ、大規模実サービスであるDRIVE CHARTを例にAIドラレコを実現するための技術要素を解説した。なお、DRIVE CHARTは、京王自動車株式会社、株式会社日立物流、株式会社首都圏物流などの協力の下、2018年4月から10月にかけて実証実験を行い、過去5年の同時期平均比で、事故率がタクシーで約25%、トラックで約48%改善したことが報告されている³⁴⁾。本稿がAIドラレコに対する理解の一助となれば幸いである。

(2021年7月31日受付)

〔文 献〕

- 1) 交通事故総合分析センター (ITARDA) : “統計資料” (2021), <https://www.itarda.or.jp/materials/traffic/freeze>
- 2) F. Sagberg et al. "A review of research on driving styles and road safety", Human Factors, 57, 7, pp.1248-1275 (2015)
- 3) D. Yi et al. "A machine learning based personalized system for driving state recognition", Transportation Research C, 105, pp.241-261 (2019)
- 4) E. Mantouka et al. "Smartphone sensing for understanding driving behavior: Current practice and challenges", Int.J. Transportation Science & Technology, in press
- 5) P. Rettore et al. "Vehicular data space: the data point of view", IEEE Communications Surveys & Tutorials, 21, 3, pp.2392-2418 (2019)
- 6) J. Wahlström et al. "Smartphone-based vehicle telematics: A ten-year anniversary", IEEE Trans. Intelligent Transportation Systems, 18, 10, pp.2802-2825 (2017)
- 7) J. Bell et al. "Evaluation of an in-vehicle monitoring system (IVMS) to reduce risky driving behaviors in commercial drivers: Comparison of in-cab warning lights and supervisory coaching with videos of driving behavior", J Safety Research, 60, pp.125-136 (2017)
- 8) D. Johnson and M. Trivedi: "Driving style recognition using a

- smartphone as a sensor platform", in Proc. International Conference on Intelligent Transportation Systems (ITSC), pp.1609-1615 (2011)
- 9) G. Castignani et al.: "Driver behavior profiling using smartphones: A low-cost platform for driver monitoring", IEEE Intelligent Transportation Systems Magazine, 7, 1, pp.91-102 (2015)
 - 10) P. Händel et al.: "Insurance telematics: Opportunities and challenges with the smartphone solution", IEEE Intelligent Transportation Systems Magazine, 6, 4, pp.57-70 (2014)
 - 11) J. Wahlström et al.: "Detection of dangerous cornering in GNSS data driven insurance telematics", IEEE Trans. Intelligent Transportation Systems, 16, 6, pp.3073-3083 (2015)
 - 12) P. Händel et al.: "Smartphone-based measurement systems for road vehicle traffic monitoring and usage-based insurance", IEEE Systems Journal, 8, 4, pp.1238-1248 (2014)
 - 13) T. Chan et al.: "A comprehensive review of driver behavior analysis utilizing smartphones", IEEE Trans. Intelligent Transportation Systems, 21, 10, pp.4444-4475 (2019)
 - 14) E. Vlahogianni and E. Barmounakis: "Driving analytics using smartphones: Algorithms, comparisons and challenges", Transportation Research C, 79, pp.196-206 (2017)
 - 15) A. McDonald et al.: "Classification of driver distraction: A comprehensive analysis of feature generation, machine learning and input measures", Human Factors, 62, 6, pp.1019-1035 (2020)
 - 16) N. Li et al.: "Modeling of driver behavior in real world scenarios using multiple noninvasive sensors", IEEE Trans. Multimedia, 15, 5, pp.1213-1225 (2013)
 - 17) S. Masood et al.: "Detecting distraction of drivers using convolutional neural network", Pattern Recognition Letters, 139, pp.79-85 (2020)
 - 18) M. Ani et al.: "A critical review on driver fatigue detection and monitoring system", Int.J. Road Safety, 1, 2, pp.53-58 (2020)
 - 19) M. Quddus et al.: "Current map-matching algorithms for transport applications: State-of-the art and future research directions", Transportation Research C, 15, 5, pp.312-328 (2007)
 - 20) M. Bierlaire et al.: "A probabilistic map matching method for smartphone GPS data", Transportation Research C, 26, pp.78-98 (2013)
 - 21) M. Haklay: "How good is volunteered geographical information? a comparative study of OpenStreetMap and ordnance survey datasets", Environment & Planning B, 37, 4, pp.682-703 (2010)
 - 22) T. Victor et al.: "Analysis of naturalistic driving study data: Safer glances, driver inattention and crash risk", SHRP2 Report S2-S08A-RW-1 (2015), <http://insight.shrp2nds.us>
 - 23) K. Campbell: "The SHRP 2 naturalistic driving study: Addressing driver performance and behavior in traffic safety", TR News, 282, pp.30-36 (2012)
 - 24) "DRIVE CHARTの裏側～AI×IoT×ビッグデータを支えるアーキテクチャ～", DeNA TechCon 2020, https://www.slideshare.net/dena_tech/drive-chart-ai-iot-231151928
 - 25) J. Redmon and A. Farhadi: "YOLO9000: Better, Faster, Stronger", in Proc. Computer Vision and Pattern Recognition (CVPR) (2017)
 - 26) Z. Cao et al.: "Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields", in Proc. Computer Vision and Pattern Recognition (CVPR) (2017)
 - 27) J. Donahue et al.: "Long-term Recurrent Convolutional Networks for Visual Recognition and Description", in Proc. Computer Vision and Pattern Recognition (CVPR) (2015)
 - 28) 内田： "モデル高速化百選", 画像センシングシンポジウム (SSII) (2019)
 - 29) A. Howard et al.: "Searching for MobileNetV3", in Proc. International Conference on Computer Vision (ICCV) (2019)
 - 30) M. Tan and Q. Le: "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", in Proc. International Conference on Machine Learning (ICML) (2019)
 - 31) "オートモーティブの大規模データ処理を支える技術後編：大規模地図データ構造の最適化", DeNA Engineers' Blog, <https://engineer.dena.com/posts/2020.03/automotive-big-data-structure/>
 - 32) 唐澤： "交通環境におけるコンピュータビジョン技術実応用：DRIVE CHART", 情報論的学習理論と機械学習 (IBISML) 研究会 (2021)
 - 33) T. Zhou et al.: "Unsupervised Learning of Depth and Ego-Motion from Video", in Proc. of Computer Vision and Pattern Recognition (CVPR) (2017)
 - 33) "AI技術の実応用と実験環境の整備～DRIVE CHARTの協見検知～", DeNA TechCon 2021, <https://techcon.dena.com/2021/session/23/>
 - 34) "最大48%の事故削減効果を実証AIとIoTを活用した商用車向け事故削減支援サービス「DRIVE CHART」を提供", プレスリリース | 株式会社ディー・エヌ・エー | DeNA, <https://dena.com/jp/press/4478>



菊地 進一 1998年、慶應義塾大学理工学部卒業。2001年、同大学大学院理工学研究科博士課程修了。慶應義塾大学、ジョージア工科大学にて、人工知能とシステム理論に関する研究教育に従事。2012年より、(株)ブレインパッド、(株)ディー・エヌ・エーなどにて、AIシステムの研究開発に取り組み。2020年より、(株)Mobility Technologies. 博士(工学)。



内田 祐介 2005年、京都大学総合人間学部卒業。2007年、同大学大学院情報学研究科修士課程修了。同年、KDDI(株)入社。以来、画像検索、画像認識、物体検出等の研究開発および実用化に従事。2016年、東京大学大学院情報理工学系研究科博士課程修了。現在、(株)Mobility Technologies AI技術開発部副部長。博士(情報理工学)。