OS03「自動運転など自動車産業における数理科学」

自動運転における数理科学研究者への期待

（第11回横幹連合コンファレンスにて）

日時：2020年10月9日（金）

場所：統計数理研究所

東京都立川市（オンライン開催）

主　催：特定非営利活動法人 横断型基幹科学技術研究団体連合

― 目　次 ―

1.　OS03 開催に当たって：自動運転における
数理科学研究者への期待 …… 1

萩原　一郎（明治大学）

2.　因果の分かる機械学習による協調制御 …… 5

萩原　一郎、ルイス・ディアゴ、安部　博枝（明治大学）

3.　自動運転のヒューマンファクター …… 25

北﨑　智之（国立研究開発法人　産業技術総合研究所）

4.　自動運転における前後方向制御のための
エネルギー最適制御の適用 …… 37

内田　博志（福山大学）

5.　自動走行システムの安全性評価手法 …… 53

今関　隆志、菅沢　深、趙　開開（東京農工大学）
望月　悠登（シチズン時計）、毛利　宏（東京農工大学）

6.　高速画像処理システムの自動運転への役割 …… 63

岸　則政（東京大学／ JST）、平野　正浩（東京大学）、
妹尾　拓（広島大学）

‘OS03 自動運転など自動車産業における数理科学”

第11回横幹連合コンファレンス

2020年10月9日
統計数理研究所にて

OS03開催に当たって：
自動運転における数理科学研究者への期待

共催：文部科学省委託事業**AIMaP**

AIMaP : Advanced Innovation powered by Mathematics Platform

明治大学 萩原 一郎

AIMaP：Advanced Innovationpowered
by Mathematics Platform，H29～R3年度）

文部科学省科学技術試験研究委託事業「数学アドバンストイノベーションプラットフォーム」は、数学・数理科学と諸科学分野・産業との協働を推進する組織的な取り組みです。九州大学マス・フォア・インダストリ研究所（IMI）が幹事拠点となり、全国12の数学・数理科学機関を協力拠点としたオールジャパン体制を築いています。

本事業の目的は、数学・数理科学の活用によりイノベーションにつながる可能性がある分野や業界等を中心に、産業界や諸科学分野において潜在する数学・数理科学へのニーズ（数学・数理科学を活用することで解決が期待される問題等）を積極的に発掘し、その問題の解決にふさわしい数学・数理科学研究者との協働による研究を促進する仕組みを、全国的ネットワークを活用する形で構築することです。

具体的な主な活動は以下の通りです。

1. 訴求活動を通した、重点化連携分野等へのアプローチ
2. 数学・数理科学と諸科学・産業界との共同研究マッチングの推進
3. 上記活動のフォローアップ、成果やノウハウ等の集約・整理、水平展開、人材育成への活用

2

開催趣旨（1／3）

自動車産業は、社会から何時も何かが重点的に求められ、一般社会からも、現在、何が重要か、分かる特徴がある。現在は、自動運転。少し前は、新動力源。このような社会からの強い要請は、1970年前後の衝突安全から始まった。

それぞれブレークスルーを必要としたが、常に強力な数理科学を必要とした。

3

日本車追い出すべく1967年米国陸運局が厳しい安全基準を課す

50マイル／hで剛壁に衝撃
ハンドル付け根の後退移動量
2．54cm(1 inch)以内

エンジンは必ず後退し、ハンドル付け根に衝撃

エンジンの後退速度が速いとハンドルの後退速度も早く、ハンドルがドライバーに激しくぶつかる。

大規模衝突モデルによるシミュレーションの成功には大きなブレークスルーが必要であった

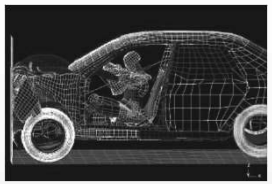

衝突シミュレーションも数理科学が大きく貢献

多くの挑戦をはね続けた現在の有限要素法シェルモデルによる車両の衝突解析の成功の秘訣

⇩

数値理論から逸脱して成功

⇩

1 集中質量マトリクスを用いた陽解法（中心差分法）

2 低減積分要素＋アワグラスコントロールの採用

3 ラジアルリターンアルゴリズムの採用により、
応力—ひずみ曲線からの逸脱を短時間で修正

4 スライディングインターフェースの採用
・・・面と面との接触の考慮が容易

萩原一郎、津田政明、佐藤佳裕、
有限要素法による薄肉箱型断面
真直部材の衝撃圧潰解析、
日本機械学会論文集（A編）、
55巻514号（1989-6月）、pp.1407-1415.

開発スタイルの変革にも数理科学が貢献

クレイ モデル ⇩
データモデル

試作車 ⇩
プリサイスモデル

実験機器 ⇩
コンピュータ・シミュレーション

自動車開発スタイルの変革

開発期間：４０～６０ヶ月→１２～２０ヶ月と大幅に短縮
ソフトハードの時代：計算科学シミュレーションなしでは
新しいハードも誕生しない
→日本メーカが最も上手に使用

→その結果、新しいハード７０～８０%は日本の自動車メーカから誕生

開催趣旨（2 /3）：5 つの話題提供を行います

1. 萩原一郎、ルイス・ディアゴ、安部博枝(明治大学)： 因果の分かる機械学習による協調制御ー高齢者ドライバー支援
2. 北崎智之（産総研）： 自動運転のヒューマンファクター
3. 内田博志（福山大）： 自動運転における前後方向制御のための エネルギー最適制御の適用
4. 今関 隆志、菅沢 深、趙 開開（東京農工大）、望月 悠登（シチズン時計）、毛利 宏（東京農工大学）：自動走行システムの安全性評価手法
5. 岸　則政（東京大／JST）、妹尾　宅（広島大）、平野正浩（東京大）：高速画像の自動運転の役割

8

開催趣旨　（3／3）
自動運転の数理科学の必要性

❶ 現在、大手自動車メーカーは、自動運転に多大な人・物・金を当て、精力的な検討を行っているが、大学の研究者の寄与はなくアカメディア側の機械系・情報系の研究者も敬遠しがちである。

❷ このことが、特にわが国の自動運転研究において本質的な進展が見られない原因となっている。今回の講演者はいずれも機械・情報系のアカデミア側の数少ない自動運転関連の研究者であり、アカデミア研究者側はどの様な研究をすべきかの良い道しるべを与えるものと期待される。

❸ 今回の講演者は全員自動車会社出身で、本質的かつ貴重な情報を与えるものと考える。今回の講演を機会に工学者と数理科学者とのコラボが進み我が国の自動運転における世界への本質的貢献を期待するものである。その中から簡単に二三次ページに簡単に示す。

シーズ情報１／高齢者ドライバー援用協調制御など自動走行車への機械学習適用研究

~畳み込み
ニューラルネットワーク~

- カナダのHinton の深層学習が第3次AIブームのきっかけ
- そのもとになったのが福島邦彦氏のネオコグニトロン

ネオコグニトロン

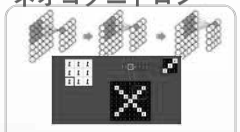

畳み込み層(特徴抽出)

プーリング層(ロバスト性)

福島邦彦氏のネオコグニトロン（ロバスト性のためのプーリング層と特徴抽出を行う畳み込み層からなる

BNN

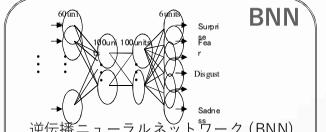

逆伝播ニューラルネットワーク（BNN）
前後の層に含まれるニューロン同士網羅的に結線

CNN

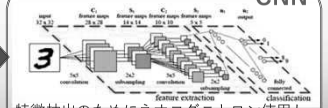

特徴抽出のためにネオコグニトロン使用し、学習は逆電波法（因果を求めるのは困難）

シーズ情報2／リアルタイムで唯一つ対応が可能なエネルギー最適制御

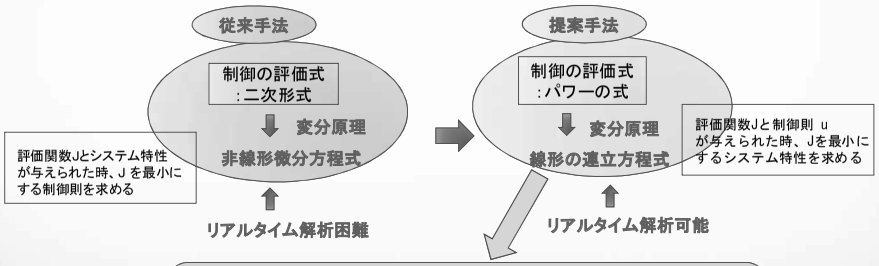

日本応用数理学会:招待論文
IEEEジャーナル論文などに掲載
日本自動車技術会論文賞:ハイブリッド電気自動車の
エネルギーフロー制御に関して**多くの企業との共同研究**

アンケート(1／2)

1.あなたのことを教えてください。
20代以下、30代、40代、50代、60代、70代

2.ご所属を教えてください。
大学等研究者（数学・数理科学分野）、大学等研究者（数学・数理科学分野以外）
産業界（その他に業界をご記入ください）、学生（数学・数理科学分野）
学生（数学・数理科学分野以外）

3.専門分野（具体的にお聞かせください）

4.研究集会を知ったきっかけを教えてください。（複数回答可）
AIMaPのホームページ、学会等のホームページ、学会等のメーリングリスト
twitter, facebookなどのSNS、関係者からの連絡（含：講演依頼）、掲示物

5.今回の研究集会には何を期待して参加されましたか。
今後の自分の研究に役立つかもしれない、新たな発想や視点を得たい
異なる分野で新たな人脈を得たい

6.実際の研究集会はいかがでしたか。
期待以上、期待通り、期待以下（その他に理由をご記入ください）

アンケート(2／2)

7.今回の研究集会で最も印象に残ったことは何ですか。
8.次回、同様の研究集会が開催される場合、また参加したいですか。
参加したい、参加しない
9.今後、数学・数理科学の研究集会で取り上げて欲しいテーマや特定の分野等があれば挙げてください。
10.【数学・数理科学分野からの参加の方にお尋ねします。】数学・数理科学を用いて取り組んでいる（今後取り組む予定の）課題やテーマを可能な範囲で教えてください。
11.現在の課題について相談できる窓口やウェブサイトがあれば利用してみたいですか。
ぜひ利用してみたい、どのようなものか興味・関心はある、有効性を感じない
12.コーディネーターやオンラインサイトを介したマッチングシステムにご興味がありますか、もしくは実際に利用を希望されますか。
ぜひ利用してみたい、どのようなものか興味・関心はあるが、まずは相談レベルで問い合わせのみ行いたい、不要
13.その他、ご意見などがございましたらお教え下さい。

アンケート

≪アンケート≫
https://forms.office.com/Pages/ResponsePage.aspx?id=iV9x12qT90q7daV6yZZG-mBzWmrlPZlMrF8u-8W7aa5UODNMV1lZU0I3MTBlQVVGWTVKTlg4V0FJOS4u

AIMaPのHP上でも掲載しております。
≪AIMaPホームページの本企画紹介ページの末尾をご覧ください≫
https://aimap.imi.kyushu-u.ac.jp/wp/event/2020a006

因果の分かる機械学習による協調制御

○萩原　一郎（明治大学）　ディアゴ　ルイス（明治大学）　安部　博枝（明治大学）

Collaborative control based on causable machine learning

* I. Hagiwara(Meiji University), L. Diago (Meiji University) , H. Abe (Meiji University)

Abstract－ Especially in the case of auto-driving level 3, causable machine learning has an important role. If the auto-driving car has the ability for risk prediction and danger avoidance based on causable machine Learning , it is very useful to support for elderly driver support. To realize this support .it will also be discussed how to get the car accident mathematical model from driving record.

Index terms－ Self-auto driving level 3, Real time machine learning, Real time optimum control theory

１はじめに

2018年4月に設立された，筆者が所属する明治大学自動運転社会総合研究所（以下，*MIAD*：*Meiji University's Institute of Autonomous Driving*）[1] では自動運転による地方創生を第1目標に進めている． 我が国では地方の過疎化が進み，医療，交通，生活品の品ぞろえなど住民へのサービスも行き届かなくなり，このことがまた過疎化を加速させている．これに歯止めをかけ，地方に活気を取り戻し，地方それぞれに魅力ある地域とすることは喫緊の課題である．自動走行車でこのような地方創生を図るべく法律面では早急に自動走行車社会を実現するための道路交通法のローカルルールを作るなどの議論がなされている．その一方で．自動走行車の実証実験が各所でなされているものの一向に実装化される気配が見られないのはとても残念である．実証実験の目的の一つは自動走行車の社会受容性や実証実験で利用者のニーズなどを検証することと1. しているが，そもそも地方にいきなり自動走行車が根づくであろうか．現に通常，実証実験では自動走行車と言いながら，緊急時に手動運転に切り替える運転手，安全を確認する保安要員も同乗，運行状況は遠隔監視システムでモニターするケースもある．自動運転の目的は運転手不足を補うこととあるが，却って運転に関わる人を増やした実証実験で利用者のニーズが正確に掴めるのであろうか．我々が提唱している協調制御の実現がこのような課題を解決すると考える．

２　自動走行車における協調制御の意義

自動車を制御するシステムと人との役割負担によって自動運転はレベル0からレベル5に分けられている[2]． レベル0は自動でない通常の車，レベル1は走る・止まるまたは曲がるのいずれかが自動， レベル2は両方が自動， レベル3は， システムからの運転操作切り替え要請（Request to Intervene　以下， RtI）に

Table1 Level of autonomous driving

Level	Overview
0	*All operation by driver*
1	*Steering operation or Acceleration & deceleration is supported by system／【Driving support】*
2	*Steering operation and Acceleration & deceleration are supported by system／【Driving support】*
3	*full automatic operation in a specific location, in an emergency operated by driver ／【automatic operation 】*
4	*full automatic operation in a specific location ／【automatic operation 】*
5	*full automatic operation without location limitations ／【full automatic operation】*

ドライバーが適切に応じるというもの． レベル4は自動運転の場所と時間を限定，レベル5は無条件自動運転である．

２．１　レベル３に必要な技術

自動運転に関わる技術開発にも各社間での協調的なものと競争的なものがある．協調的技術開発には，2014年６月から始まったSIP自動走行システム（SIP Automated driving systems for universal service SIP－adus）などで実施されている，ダイナミックマップ，HMI（Human Machine Interface），情報セキュリティ，歩行者事故低減，次世代都市交通等がある[3]．後者の競争的技術課題として，① 車自身がどのような危機が潜んでいるか察知し，対応策のデータベースを基に事故の回避，② 商品性を左右する乗り心地特性の獲得等がある．人の情報処理過程は，① 感覚器官を通じて外部から入手した情報を脳の中枢で処理する「知覚」，② 得られた情報が何を意味しているのかを理解する「状況理解」，③ 直面している状況への対応に必要な行為を選択する「行為選択」，④ 意図した行為の達成に必要な一連の動作の順を追って実行する「行為実行」とされている[4]．レベル３では，「知覚」としてシステムからのRtIを受け取ることになるため，的確な「行為実行」のために「状況理解」と「行為選択」を補う必要がある．このようなことが可能か等の議論がなされているがこれ

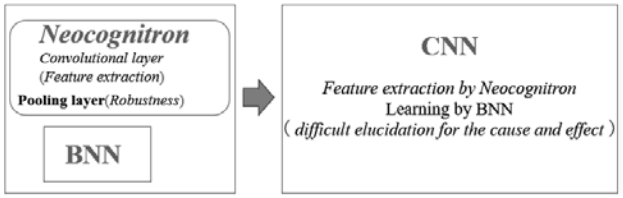

Fig.1 CNN consists of Neocognitron and BNN

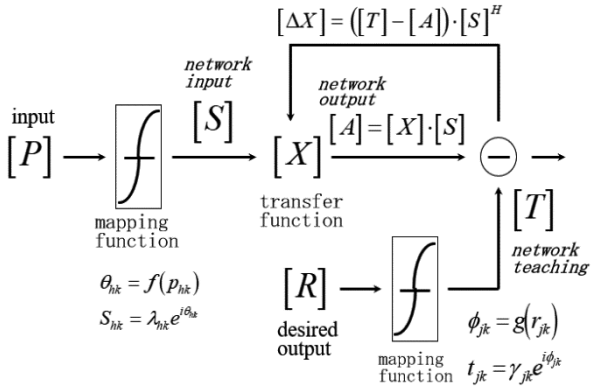

Fig.2 Structure of Holographic Neural network

Fig.3 Neuroface Lab Architecture

は現状では困難であろう. この実現には, ① RTI の際, その理由もシステムがドライバーに明確に伝えることができること, ② RTI を受け取るドライバーの集中度を迅速に高めることができること, ③ その対応策を運転者が正しく選択できること, である. ①, ③ に対しては, 機械学習を用いることが有効であると考えられるが, 現在主流の福島邦彦氏のネオコグニトロン[5] ベースの畳み込みニューラルネットワーク (Convolutional Neural Network 以下, CNN)[6] では図１に示すように元々因果の確認が困難な逆伝播法ニューラルネットワーク(BNN)を学習に取り入れている関係でシステムの運転継続の是非の判断はできても, その理由などをドライバーに呈示することは難しい. そこで, 筆者らが長年, システム同定[7)~10)], 最適化[11)~24)] を始めとする様々な分野で応用し, 機械学習の学習プロセスが示せるという点で評価が与えられているファジイ推量化理論第Ⅱ類組込みホログラフィックニューラルネットワーク (HNN) (Fuzzy quantification Holographic Neural Network 以下, FQHNN)[25)] を利用することにする. ここで簡単のため図２には HNN 部分のみ記す. 同図に示すように HNN 自体, 入力と出力の関係式がマトリクス形式で得られるため, 出力に対する各入力データの影響度が得られることとなる. 更にファジイ推論第Ⅱ類も各パラメータの重みを表現できる. それらの重畳を利用する FQHNN では癒しを始めとする感性に利用されその効果が示されている[25)~29)].

２．２　乗員の表情分析で安心度を計測

② に関しては顔表情だけで集中度を計測し集中度を高める検討を行うため図３に示すようなシステムの構築を行っている[30)], システム構築に使用した PC は, ノート型の Panasonic 製 CF-LX6, 表情の録画は付帯しているカメラ, 脳波測定に使用した脳波計は, 被験者の負担軽減とデータ解析の簡便性から NeuroSky 社製 mind wave mobile を用いた. mind wave mobile は, センサーを被験者の額部分に接触させ, 耳にイヤーパッドを取り付けるだけで容易に脳波の計測が可能であり, 簡易に実験を行える点で採用した. また mind wave mobile で取得した脳波は NeuroSky 社で開発された独自のアルゴリズム eSense により, 集中度(Attention)を示す基準と解釈された低い状態 0 から高い状態 100 までの値を得ることができる[31)]. ここでは, eSense で得られる集中度の値を表情分析で得る教師データとして用いる. この結果については当日述べる. このシステムは, 乗員の表情分析で安心安全を見る事にも利用する.

２．３　自動車開発における従来技術との関連

車両を市場に出すには, 図４に示すように互いにトレードオフの関係にある多くの性能を同時に満たす必要がある. そのため, 開発期間の短縮を行うには図５に示すような車両開発の変革が必要となった. すなわち, クレイモデルを造りそれを元に試作車を造り実験で図４の性能を確認するのでは, 新車を企画してから市場に出るまで 40 ケ月から 60 ケ月を要した. それで図５

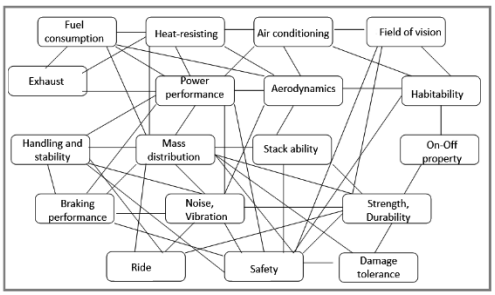

Fig.4 Relevance of performance

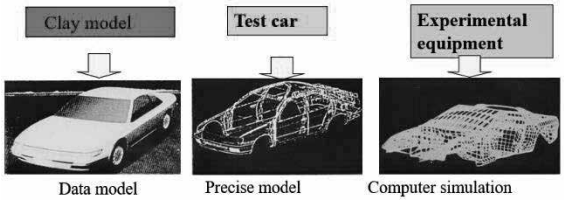

Fig.5 Revolution of developing automobile

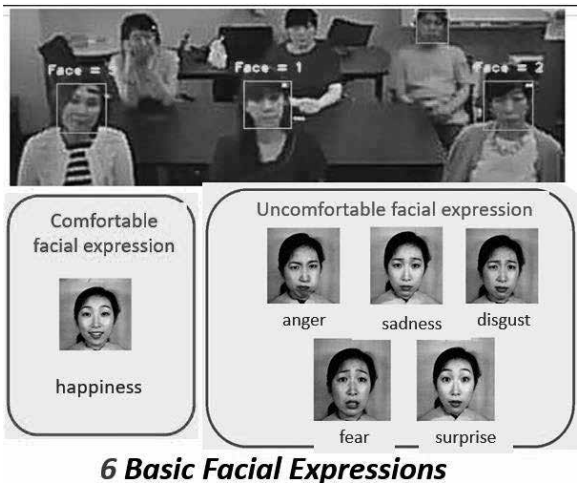

Fig.6 Comparison between facial expressions extractedin real time and brain waves of plural persons

のように, クレイモデルの代わりに 3 次元 CAD データ, 試作車の代わりにプリサイスなモデル, 実験の代わりにコンピュータシミュレーション, この変革により, 開発期間は 12 ケ月～20 ケ月と大幅な短縮が得られた. このようにコンピュータシミュレーションの効果は絶大であったが, 人間特性に関わる乗り心地, 操縦安定性, 音質などは容易にシミュレーションには乗らなかった. そこで筆者はドライバーの表情でこれらの人間特性を図ることを提唱し [32)～36)], ローカル CSRBF 等を中心とする画像処理技術 [37)～43)] と上述の機械学習技術の開発を行ったわけである. 今までの研究はドライバー一人を対象とするものであったが, 自動走行車では図 6 に示すように複数の表情分析が必要となる.

3　ドライブレコーダーで事故を観察し, 対応モデルの構築

ここでは, ドライブレコーダー(DR)などで事故を観察しその対応モデルを構築し, 対応が得られた後, パラメータを変えて深層学習のデータとして構築するためのモデリングと制御について述べる. どのような危機が潜んでいるかの察知とその対応法の獲得の一つの手段に, ドライブレコーダー（以下, *DR*）の活用がある. *DL* で事故を調査し, どのように危険の予兆に気づくべきか, 2) 車両モデルから事故を分類し, 各部類からまず一例ずつ危険回避の対応モデルを構築しパラメータを変えて多くの学習データを蓄積し, 深層学習

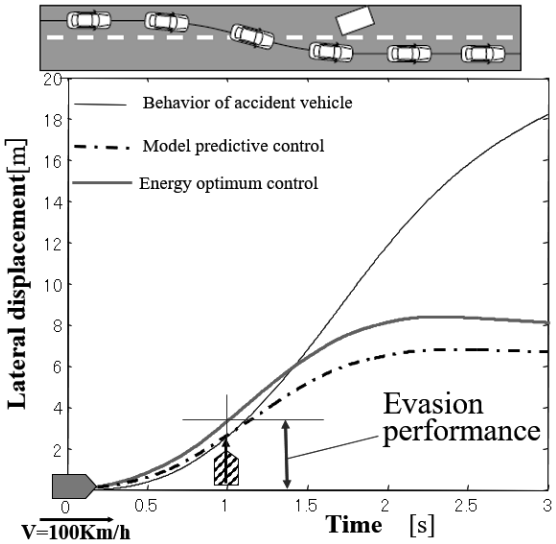

Fig.7 Behavior of accident vehicle and Response by control theory

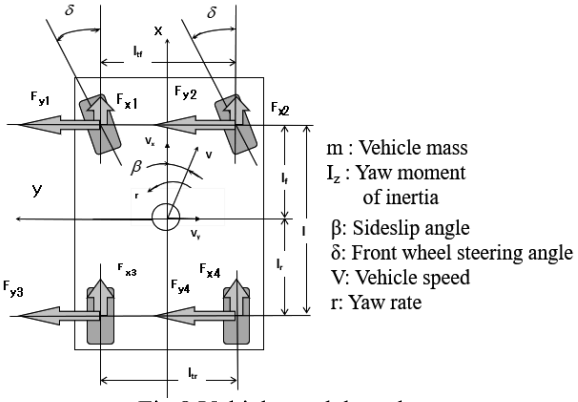

Fig.8 Vehicle model used

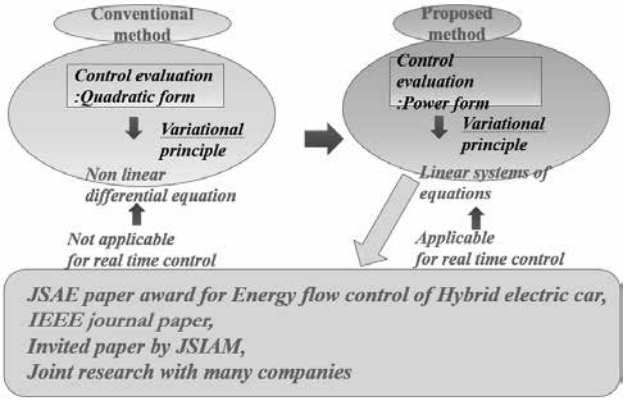

Fig.9 Placement of new Energy optimum control theory : only one applicable for real time control

が機能できるようにする. これを各事故の部類別で実施し, *DL* から深層学習データを構築するための方法論を確立する. 図 7 は, 事故車の挙動を示す [44)]. 突如大きく左に振れ左の側溝に衝撃した様子を示す. 事故車は, 時速 100 km で走行し, 到達時間 1 秒の前方に障害物

の飛び出しを発見したドライバーが，急激なハンドル操作によって障害物を回避しようとした結果と分かった. このように車両自身が障害物を察知した際, どの様にすべきであったかの学習をさせることが重要である. ここでは，まず図７の事故に対し図８の車両モデルを利用する. いちいち車両モデルを作成するのでは大変であるため, 車両モデルのストックも今後大切である. 現在，自動車会社で使用されている制御則はモデル予測制御則が中心である. 所謂最適制御は, 図９に示すようにリアルタイムで得ることは困難であり実機への適用は容易でない. そこでリアルタイムの制御が可能な福島らのエネルギー最適制御理論（*EOC*）[45-48] を利用する. 従来の最適制御の評価関数は二次形式であるが，*EOC* では，評価関数は二次形式でなくパワーで表される L 関数の時間積分 J としている. L 関数は，各輪タイヤの横滑りによる散逸パワー P ，陀角を制御することで発生する横力 U による制御入力パワー，それに，*EOC* 特有の仮想パワー g からなる. 本課題に対しては，仮想パワー g として，目標ヨーレートと現在のヨーレートの偏差に現在のヨーモーメントを掛けたものを利用すると，図７の点線図の良好な結果が得られた. すなわち，制御なしの事故車では，横すべりが大きくヨー角ゼロの状態に戻っていない. 一方，*EOC* では，車速 100［km/h］の直進状態から振幅 120 度の正弦波状の操舵を 2 秒間続け再び直進状態に戻すと目標値以

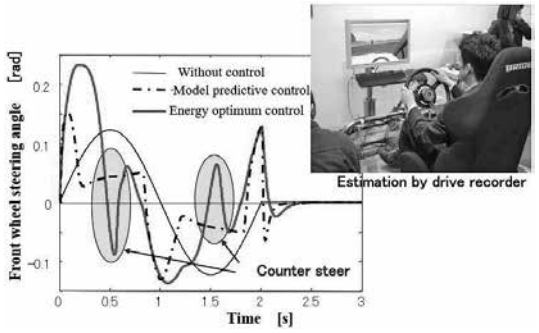

Fig.10 Front wheel steering angle-Time

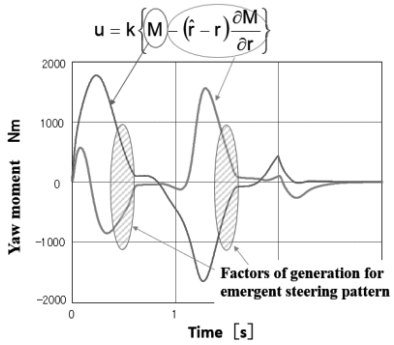

Fig.11 Yaw moment-Time

上のヨーレートが発生し，回避性能の目安となる 1 秒時の横変位が大きく起こるなど, 緊急回避性能が高い. 例えば, 図 10 で見るように，初期の大舵角により目標値よりも大きいヨーレートを発生させた後，舵角が横速度に大きい影響を与える前に逆操舵しあたかもプロドライバーがカウンターステア（あて舵）で横速度を過大に発生することを防ぐような効果が実現できている. 更に図 11 に示すように *EOC* 特有の, 現在生じているタイヤのヨーモーメントに抗して目標値に近づけるように作用する仮想パワーが効果的に作用していることが分かる. 以上，図 8 のモデルと *EOC* の L 関数を構築しておくと，自車速度や障害の位置情報を色々に変えて自動運転車の事故回避のための操作のデータベースを得ることが出来る. このように，*EOC* では，ベテランドライバーの操作を模擬する仮想パワー g を見つけることで極めて良いモデルとなり，深層学習の良好なデータを得ることが可能となる.

４　自動運転実装化のための社会システム

2020 年度の自動運転レベル 3 実現に向けた道交法の改正案では，自動運転のレベル 3 走行時において，運転者に安全運転の義務は課すものの，運転者は自動運転時にスマートフォン操作などのタスクも許されることになる. ただ地方創生にとって重要なのはやはり各地方の状況に即したローカル版レベル 3 である. そもそも自動運転車が実装されるためには，バス運営会社の黒字化なしでは困難である. 自動運転車は電動化であったり，AI が組み込まれたりと通常の車両すなわちレベル 0 の自動運転車に比較して，整備もより複雑となる. そこで，AI にも精通し自動運転車の整備もできる高級技術者・技能者の養成も並行して行うことも重要となる. バス会社がこのような養成に絡むなどして黒字化にも努める. 繰返しとなるが, 地方でいきなりの運転者不在のレベル 4 は，乗客に不安感を与え定着は困難であろう. ドライバー自身が上述の養成教育を受け，問題意識を持ってレベル 3 の自動運転車に乗り，乗員の様子などから，乗員はどのあたりで不安感を抱くかなど，乗りながら問題点とその解決案を整理し自動運転車にフィードバックする. このような状況を継続していくうちに，乗客の間に「結局ドライバーは何もしていないではないか」の世論が生まれてくるであろう. その段階でレベル 3 から，レベル 4 に切り替える. 以上の達成のための方策の詳細は省略するが, このようなことが達成されるよう検討を進めているところである.

５　まとめ

我が国では超高齢社会を迎え地方の過疎化が進んでいる.各地域に自動運転バスを中心に適切で持続可能なモビリティを実現するための社会システムについて考察した.地方にあっては,自動走行の機能を持った上で例えば高齢者ドライバーの運転を支援する機能を追加した方式がよりふさわしいこと,それを実現する技術について独自の機械学習技術と制御についても述べた.今後も本稿で述べたことが一刻も早く実現されるよう努力を続けてゆく所存である.

参考文献

1) https://www. meiji. ac. jp/osri/topics/2017/6t5h7p00000qwclo. html

2) SAE international. On Road Automated Vehicle Standards Committee. Standard J3016. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles J3016_201806, 2018

3) 葛巻 清吾, SIP自動走行システムの取り組み, 日本機械学会誌Vol. 121, No. 1191(2018-2), pp. 16-19

4) 稲垣 敏行, 自動運転における人と機械の役割と協調に関する検討課題, Journal of Society of Automotive Engineers of japan. Vol. 73(2019), pp. 4-9

5) Fukushima, K., Neocognitron, "A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position". *Biological Cybernetics* **36** (4): 93-202

6) https://www. youtube. com/watch?v=zl99IZvW7rE

7) 萩原一郎,井上亜友子,施勤忠,ニューラルネットワークと計算力学に基づくシステム同定の検討,日本機械学会論文集(C 編),64 巻 621 号 (1997-5 月),pp. 1574-1579.

8) 施勤忠,萩原一郎,ニューラルネットワークと計算力学に基づくシステム同定の検討,第２報;計測点の低減法に関する研究,日本機械学会論文集(C 編),64 巻 625 号(1998-9 月),pp. 3375-3382.

9) 施勤忠,萩原一郎,関根俊彰,ニューラルネットワークと計算力学に基づくシステム同定の検討,第３報,構造物の広範囲欠陥同定法の研究,日本機械学会論文集(C 編),65 巻 635 号 (1999-7 月),pp. 2771-2778.

10) 施勤忠, 萩原一郎, 蘇翔,ニューラルネットワークと計算力学に基づくシステム同定の検討(第５報,欠陥同定における計測パラメータの選択と最小化),日本機械学会論文集 (C 編) ,68 巻 667 号(2002-3),pp754-760.

11) 萩原一郎,施勤忠,小机わかえ,目的関数のニューラルネットワーク推定による衝撃最適設計法の開発,日本機械学会論文集(A 編),63 巻 616 号 (1997-12 月),pp. 2510-2517.

12) 施勤忠,萩原一郎,畔津,依知川哲治,ホログラフィックニューラルネットワークを用いた音響最適設計,自動車技術会論文集,29 巻３号 (1998-７月),pp. 93-98.

13) 萩原一郎,施勤忠,高島太,目的関数のニューラルネットワーク推定による衝撃最適設計法の開発 (第２報：車両部品構造への適用) ,日本機械学会論文集(A 編),64 巻 626 号 (1998-10 月),pp. 2441-2447.

14) 施勤忠,萩原一郎,高島太,曲面応答法による多峰性問題の最適設計法の開発,日本機械学会論文集(A 編),65 巻 630 号 (1999-2 月),pp. 232-239.

15) Q. Shi, I Hagiwara, S. Azetsu, T. Ichikawa, Holographic Neural Network Approximations for Acoustics Optimization, JSAE Review, Japan Society ofAutomobile Engineering, Vol. 19 No. 4 (1998-10), pp. 361-363.

16) 岩波健,施勤忠,萩原一郎,長松昭男,鉄道車両の振動低減に関する研究 (応答曲面法による床下機器配置最適化の基礎検討) ,日本機械学会論文集(C 編),66 巻 641 号 (2000-1 月),pp. 240-246.

17) 施勤忠,萩原一郎,高島太,戸倉直,多峰性最適化解析技術を用いた車体と乗員拘束装置の適合に関する研究,自動車技術会論文集,Vol. 31, No. 3(2000-7 月),pp. 107-113.

18) Q. Shi and I. Hagiwara, Optimal Design Method Using Holographic Neural Network's Approximation to Automobile Problems, JJIAM(Japan Journal of Industrial and Applied Mathematics), Vol. 17-3(2000), pp. 240-247.

19) Q. Shi, I. Hagiwara and F. Takashima, Global Optimization to Multiple Local Optima with Response Surface Approximation Methodology, JSMEInternational Journal Series A, Vol. 44, No. 1(2001), pp. 175-184.

20) I. Hagiwara, Q. Shi, Z. Rao and, D. Wang, Optimal Placement of PiezoelectricActuators to Interior Noise Control, IUTAM Symposium on Smart StructuresandStructronic Systems(2000), U. Gabbert and H. S. Tzou eds., KLUWER ACADEMICPUBLISHERS, pp. 247-254.

21) 鎌田慶宣, 福島広隆, 萩原一郎, 応答曲面法を用いた低周波数域車内音の低減最適化技術, 日本機械学会論文集, 第 68 巻, 673 号 C 編 (2002-9), pp. 2556-2563.

22) I. Hagiwara, D. W. Wang, Q. Z. Shi, R. S. Rao, Reduction of Noise Inside a CavitybyPiezoelectricActuators, ASME Journal of Vibration and Acoustics, Volume125, No. 1(2003-1), pp. 12-17.

23) 萩原一郎,山本千尋,陶金,野島武敏,反転らせん型モデルを用いた円筒形折り紙構造の圧潰変形特性の最

適化検討, 日本機械学会論文集 A 編 70 巻 689 号 (2004/1), pp. 36-42.
24)福島広隆, 鎌田慶宣, 萩原一郎, MPOD 法を用いたエンジンマウントの配置最適化, 日本機械学会論文集 C 編 70 巻 689 号(2004/1), pp. 54-61.
25)Diago, L. , Kitaoka, T. , Hagiwara, I. and Kambayashi, T. , Neuro-Fuzzy Quantification of Personal Perceptions of Facial Images Based on a Lim ited Data Set IEEE Transactions on Neural Networks 22(12): (2011-12), pp. 2422-2434
26) L.Diago, T.Kitaoka,I.Hagiwara,Development of a System for AutomaticFacial Expression Analysis, Journal of Computational Science and Technology,Vol.2, No.4(2008-8),pp.401-412.
27)T.Kitaoka,L.Diago,S.Kitazaki,I.Hagiwara,S.Yamane,Definition,Detectionand Generation of Iyashi Expression, Journal of Computational Science andTechnology, Vol.2, No.4(2008-8), pp.413-422.
28) 北岡哲子, 田中兼一, 北崎智之, 萩原一郎, 癒し構造分析とグッズの分析・評価への応用：日本感性工学会論誌, Vol. 9, No. 1, pp. 43-49(2009).
29)T. Kitaoka,L.Diago,I.Hagiwara,S.Kitazaki,Development of Facial ExpressionAnalysis by Fuzzy Quantification Theory II—Comparison with Holographic NeuralNetworks— GESTS International Transactions on Computer Science and Engineering,Vol.55,No.1(2009.8),pp.97-108.
30) 安部 博枝, Luis Diago, 萩原 一郎, 自動運転時の表情から状態測定を予測するための検討, 日本機械学会計算力学講演会 (2019, 9).
31)Luo, A. and Sullivan, T, J., A user-friendly SSVEP-based brain-computer interface using a time-domain classifier, Journal of Neural Engineering, Vol.7, No.2 (2010) p.10.
32) 萩原一郎,「人と機械の知的協調システム」ミニ特集を組むに当たって, 計測と制御, 第 38 巻第 6 号 (1999/6), pp355-356.
33) 萩原一郎, コラボレーションデザインの現状と課題, 設計工学, Vol. 36, No. 6(2001 年 6 月), pp. 231-239.
34) 萩原一郎, IT 時代のディジタル設計の現状と今後, 研究技術計画, Vol. 16, No. 1. /2/2001(2003-8), pp. 40-46.
35)萩原一郎, 昨今のデジタル設計技術, シミュレーション, 第 25 巻, 第 4 号(2006-12), pp230.
36) 萩原一郎, 感性と自動車 (乗り心地の科学), 繊維学会誌 Vol. 64, No. 9(2008), pp. 287-290.
37)Nikita Kojekine, Vladimir Savchenko, Michail Senin, Ichiro Hagiwara,"A prototype System for Character Animation Based on Real-time Deformations",The Journal of Three Dimensional Images,Vol. 16, No. 4 (2002/12), pp. 91-95.
38)仲田晋, 萩原一郎, リフティングスキームによる四辺形メッシュの多重解像度表現, 情報処理学会論文誌, 第４４巻第４号(2003/4), pp. 1121-1131.
39)REN,Bingyin,HAGIWARA Ichiro,Composite Freeform Surface ReconstructionUsing Recursive Interpolating Subdivision Scheme,Computers in Industry50(2003),pp.265-275.
40)N.Kojkine,I.Hagiwara and V.Savchenko,Software tools using CSRBFs forProcessing Scattered Data,Computers & Graphics (2003),pp.311-319.
41)Nikita Kojekine, Vladimir Savchenko, Michail Senin, Ichiro Hagiwara,Anapproach to surface retouching and mesh smoothing,Visual Computer(2003)19:1-16.
42)V. Savchenko,M. Savchenko, O. Egorova, I. Hagiwara,Surface SimplificationBased On a Statistical Approach, WSEAS Transactions on
circuits and systems, vol. 3, no. 1,pp.159--164, Jan. 2004.
43)カジョキン ニキタ, 谷口由紀, 萩原一郎, サブチェンコ ウラディミール, CSRBF 法による表面修復, 情報処理学会論文誌, 第４５巻第４号
(2004-4), pp. 1202-1211.
44) 萩原一郎, AI学習を応用した自動運転レベル3実現のための要素技術, 車載テクノロジー (2019-10), pp. 65-68.
45) 福島 直人, 萩原 一郎, エネルギー最適制御理論—最適制御理論の新しい枠組みとその発展性について, 応用数理, Vol. 21, No. (2011-12), pp. 259-275
46) 福島 直人, 萩原 一郎, エネルギ収支に着目した新しい最適制御理論の構築とその適用, 応用数理, Vol. 17, No. 2, 2007-6月, pp. 42-58
47) Fukushima, N. , Arslan, M. S. and Hagiwara, I. , An Optimal Control Method based on the Energy Flow Equation, IEEE Transactions on Control Systems Technology, Vol. 17, No. 4, 2009, pp. 866-875
48) 内田 博志, 福島 直人, 萩原 一郎, エネルギー最適制御理論に基づくハイブリッド電気自動車のエネルギーフロー制御, 自動車技術会論文集 Vol. 41, No. 2 (2010 年 3 月), pp. 461-468

令和２年10月9日

第11回横幹連合コンファレンス

／ OS03 自動運転など自動車産業における数理科学

因果の分かる機械学習による協調制御

明治大学　先端数理科学インスティテュート(MIMS)
＆自動運転社会総合研究所(MIAD)

萩原一郎、ルイス・ディアゴ、安部博枝

本日の発表内容

❶ 簡単な自己紹介

❷ 明治大学自動運転社会総合研究所MIADの活動

❸ 自動車産業に機械学習が取り入れられたきっかけ

❹ 自動車産業におけるAI こと始め（それは第2次AIブームの時だった）

❺ 地方創生のための自動走行車とその機械学習

概要

自動運転車レベル3では、基本的に自動走行車が運転し、ドライバーは解放されてほっとしている。そこに急に運転代われと言っても直ぐの対応は困難。

これを可能にするのは、「車自身がなぜ危険か察知しドライバーが直ちになすべきことを伝える」が出来て初めて可能となる。それには因果のわかる機械学習が望まれる。これが実現できれば、究極のドライバーと自動走行車の協調であり高齢者ドライバーの問題も解決できることを述べる。

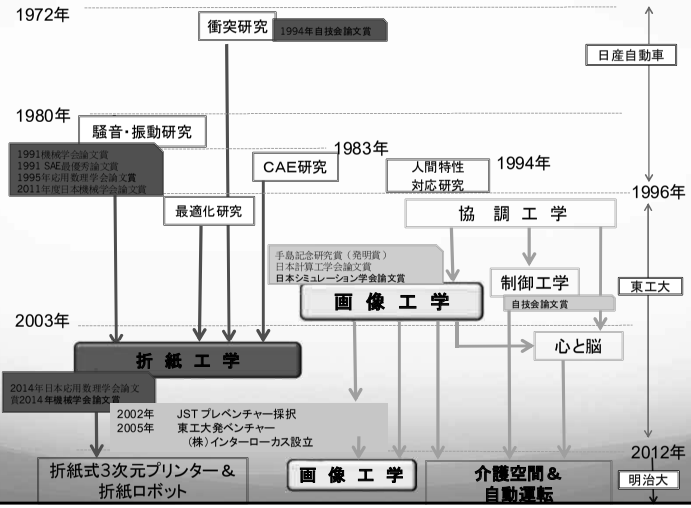

過疎地での自動運転車輌の重要性

1．高齢化と人口減少による環境の変化

（1）生活関連サービス（小売・飲食・娯楽・医療機関等）の縮小
（2）税収減による行政サービス水準の低下
（3）地域公共交通の撤退・縮小

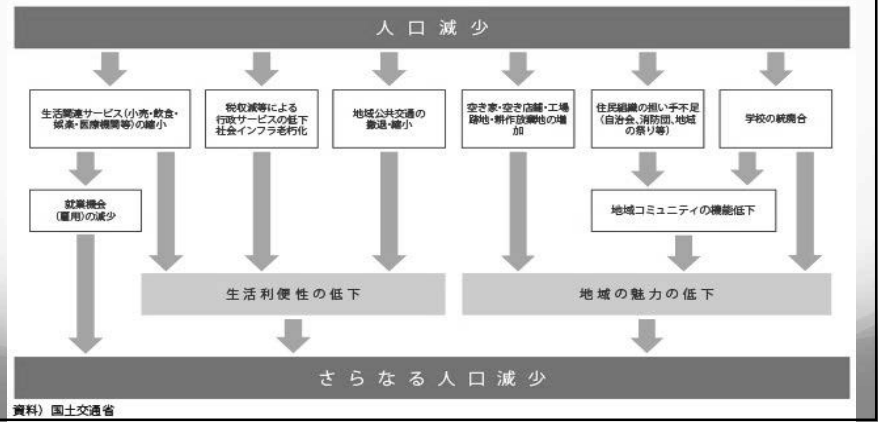

資料）国土交通省

- 2018年2月20日　企画会議、懇親会
- 2018年3月28日　設立記者会見
- 4月28日　開所式

記者発表
MIAD は技術、法律、保険、地方創生の
4つの部門からなる。

対馬・五島列島中心九州地区自動運転FCV車社会構築構想

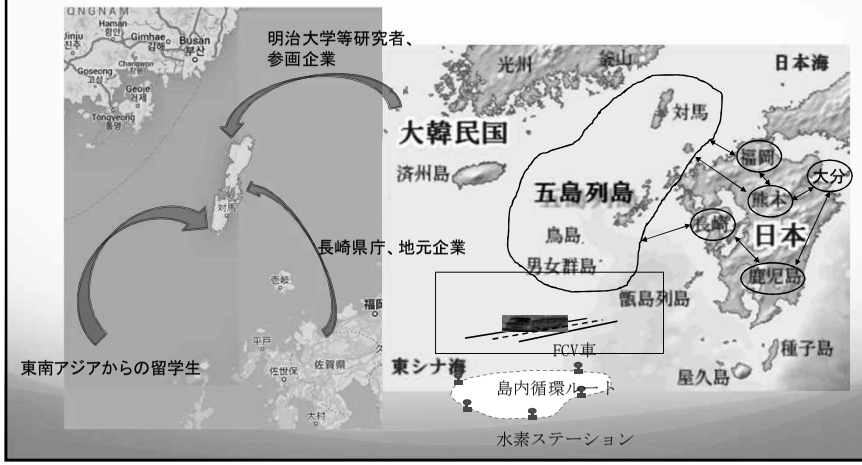

技術部門／独自の画像処理・機械学習・制御

- 深層学習の成果による自動運転技術の大幅な進歩
- 乗り心地などの人間特性に関わる性能評価はドライバーから同乗者へ

自動化レベル	概要
レベル0	ドライバーがすべてを操作
レベル1	システムがステアリング操作、加減速のどちらかをサポート／【運転支援】
レベル2	システムがステアリング操作、加減速のどちらもサポート／【運転支援】
レベル3	特定の場所でシステムが全てを操作、緊急時はドライバーが操作／【自動運転】
レベル4	特定の場所でシステムが全てを操作／【自動運転】
レベル5	場所の限定なくシステムが全てを操作／【完全自動運転】

レベル2:
日産「プロパイロット」
ベンツ「ドライブパイロット」

レベル3:アウディA8

概要

自動運転研究:競争的研究と協調的研究

協調的研究:SIP自動走行システム
(SIP Automated driving systems for universal service, SIP-adus)などで実施

2014年6月から始まったSIP自動走行システム:

重点的に
ダイナミックマップ,
情報セキュリティ,
HMI(Human Machine Interface),
歩行者事故低減,
次世代都市交通
の5課題

SIP:Cross-ministerial Strategic Innovation Promotion Program

概要

競争領域は:所謂機械工学・情報科学が中心.

しかし、もっと重要なのは応用数理

主なテーマ:予防安全, 衝突安全, 運転制御, 人間工学など

❶ レベル3:「システムからドライバーへの受け渡しにどれくらいの遷移時間が必要か」という議論
⟹ 筆者らのグループでは脳波計と表情認識の同期により集中度が迅速に最高度にたどり着くための基礎検討.

❷ SIP-adusでも取り上げられているように, レベル3以上では,「高齢者や車椅子などの歩行制約者に優しいART(Advanced Rapid Transit)」は特に重要

❸ 自動運転車では安心感が今一つ持てなかったり. 逆に緊張感がない場合は車酔いの問題の発生

❹ 所謂魅力品質を高める努力が重要. そのためには, やはり自己位置と共に他車との関係性のリアルタイムな把握, 事が生じた時の余裕を持った対応が重要となる. その解決には筆者らのAI技術やリアルタイム最適制御技術が有効に機能.

車両開発方式のイノベーションと自動車産業に機械学習技術が取り入れられたきっかけ

設計モデル例

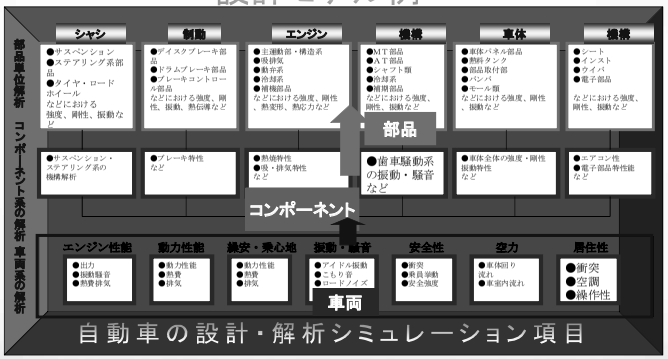

車両モデル、コンポーネント、部品、各段階での設計モデル
（車両全体→コンポーネント→部品への性能の落とし込み）
↓
残された課題⇒乗り心地、音質、操縦安定性と心に関する特性

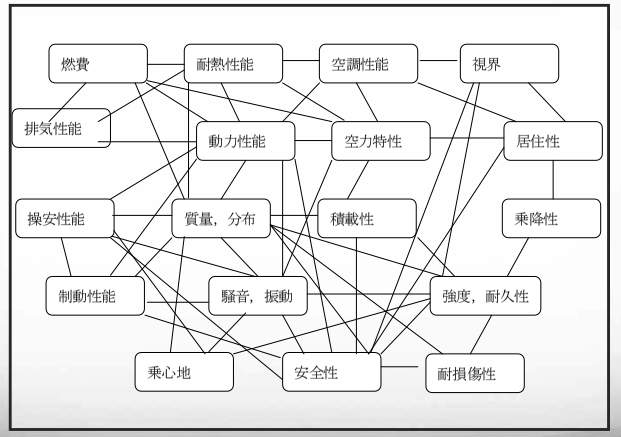

性能間の関連

日本車追い出すべく1967年米国陸運局が厳しい安全基準を課す

50マイル／hで剛壁に
衝撃
ハンドル付け根の
後退移動量
2．54ch以内

エンジンは必ず後退し、
ハンドル付け根に衝撃

エンジンの後退速度が
速いとハンドルの後退
速度も早く、ハンドルが
ドライバーに激しくぶつ
かる。

衝突シミュレーションの成功により 計算科学による開発スタイルの変革

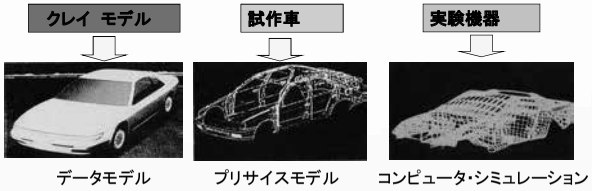

自動車開発スタイルの変革
開発期間：４０～６０ヶ月→１２～２０ヶ月と大幅に短縮
ソフトハードの時代：計算科学シミュレーションなしでは
新しいハードも誕生しない
→日本メーカが最も上手に使用
→その結果、新しいハード７０～８０%は日本の自動車メーカから誕生
→残された課題：乗り心地、操縦安定性、音質、など心に関する特性

残された課題：心に関係する特性開発

人と機械の協調

萩原一郎、「人と機械の知的協調システム」ミニ特集を組むに当たって、計測と制御、第38巻第6号(1999/6)

人に優しい機械環境の構築

MITの
スマート空間の
概念に波及

自動車産業におけるAI　こと始め
（それは第2次AIブームの時だった）

ドライバーの満足度を表情で測るコンセプトの提唱（1996年）

新しい感性工学からのアプローチ：運転者の表情でドライバーの満足度把握

自動車自身が人間の感情を読みとる！

機械はどうやって人間の感情を見知できるのだろう？
- **画像データ**
- **音声データ**
- **サーモデータ**

知ってましたか？
人間はコミュニケーションで
言語：7%
表情：55%

だったなんてこと
まずは表情の認識！！

機械はどうやって人間の感情を見知できるのだろう？
- **画像データ** ➡ **表情認識**
- **音声データ**
- **サーモデータ**

使えそうなデータは全部つかっちゃえ
センターフュージョン

心理学面での表情認識：6基本表情の認識

・怒り，嫌悪，恐怖，悲しみ，幸福，驚きの6つの基本的な表情．

・人種や，文化，性別などに関係なく万国共通．

6基本表情

FAU（Facial Action Unit）の種類

AU No.	AU名	AU No.	AU名
1	眉の内側を上げる	20	唇両端を横に引く
2	眉の外側を上げる	23	唇を固く閉じる
4	眉を下げる	24	唇を押えつける
5	上瞼を上げる	25	顎を下げずに唇を開く
6	頬を持ち上げる	26	顎を下げて唇を開く
7	瞼を緊張させる	27	口を大きく開く
8	唇を互いに接近させる	28	唇を吸い込む
9	鼻にしわを寄せる	29	下顎を突き出す
10	上唇を上げる	30	顎を左右にずらす
11	鼻唇溝を深める	32	唇を噛む
12	唇両端を引き上げる	35	頬を吸い込む
13	唇を鋭く引き上げる（頬を膨らませる）	41	上瞼を（力なく）下げる
14	えくぼを作る	42	薄目
15	唇両端を下げる	43	閉眼
16	下唇を下げる	44	細眼にする
17	下顎（おとがい）を上げる	45	まばたく
18	唇をすぼめる	46	ウィンクする
			眼球の回転

（AUは全体で44個あるが，番号は途中が抜けているので46までである）

実現されているFAUのリスト

FAUにより表現した6基本表情

Expression	Facial Action Unites
Surprise	1+2+5+26
Fear	1+2+4+5+7+20+26
Disgust	4+9+17
Anger	4+5+7+10+26
Happiness	6+12(+26)
Sadness	1+4+15

階層型NNによる6基本表情認識（小林ら）

- 手順

1．AUに対応する30特徴点を指定し

中立の顔表情からの移動量を計算

2．ニューラルネットワーク（NN）へ

移動量を入力，6基本表情を出力

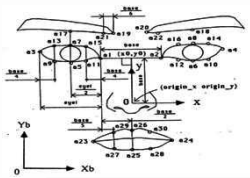

顔の特徴点

3．NN による学習と表情認識

$$sig(x) = \frac{1}{1+e^{-x}}$$

$$w_{kj}^{(n+1)} \leftarrow w_{kj}^{(n+1)} - \eta \frac{\partial R(W)}{\partial w_{kj}^{(n+1)}}$$

$R(W)$が二乗誤差$\frac{1}{2}\Sigma_j\left(t_j - y_j^{(N)}\right)^2$であるとき

$$w_{kj}^{(n+1)} \leftarrow w_{kj}^{(n+1)} - \eta\delta_j^{(n+1)} y_k^{(n)}$$

$y_k^{(n)}$は第n層の第kノードの出力

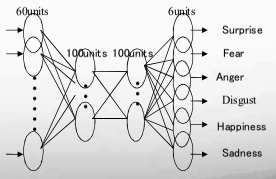

6基本表情認識用BNN
（バックプロパゲーションニューラルネットワーク

HNNは、入出力データの複素平面への写像により、入出力関係が線形に表せる事を利用した
ニューラルネットワークである。例えば、非線形関数：**r=f(p)** を近似する。

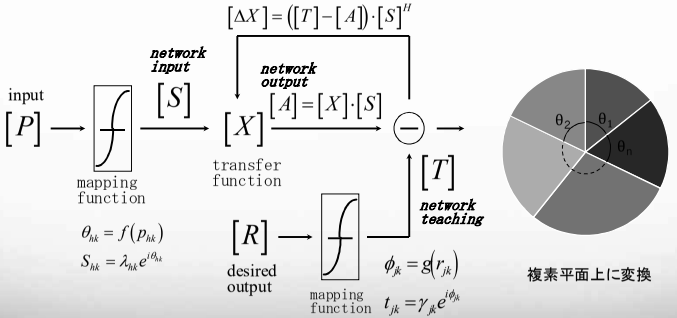

ホログラフィックニューラルネットワーク（HNN）

HNNの入力データ

❖「癒し計測システム」で使用した６３の特徴点

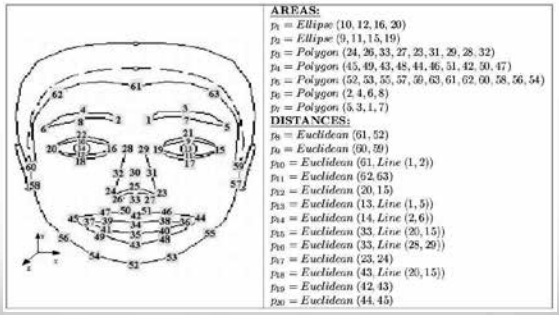

AREAS:
p_1 = *Ellipse* (10, 12, 16, 20)
p_2 = *Ellipse* (9, 11, 15, 19)
p_3 = *Polygon* (24, 26, 33, 27, 23, 31, 29, 28, 32)
p_4 = *Polygon* (45, 49, 43, 48, 44, 46, 51, 42, 50, 47)
p_5 = *Polygon* (52, 53, 55, 57, 59, 63, 61, 62, 60, 58, 56, 54)
p_6 = *Polygon* (2, 4, 6, 8)
p_7 = *Polygon* (5, 3, 1, 7)
DISTANCES:
p_8 = *Euclidean* (61, 52)
p_9 = *Euclidean* (60, 59)
p_{10} = *Euclidean* (61, *Line* (1, 2))
p_{11} = *Euclidean* (62, 63)
p_{12} = *Euclidean* (20, 15)
p_{13} = *Euclidean* (13, *Line* (1, 5))
p_{14} = *Euclidean* (14, *Line* (2, 6))
p_{15} = *Euclidean* (33, *Line* (20, 15))
p_{16} = *Euclidean* (33, *Line* (28, 29))
p_{17} = *Euclidean* (23, 24)
p_{18} = *Euclidean* (43, *Line* (20, 15))
p_{19} = *Euclidean* (42, 43)
p_{20} = *Euclidean* (44, 45)

HNNの入力データ

❖正規化した17の顔パラメータ

Face parameters
Area parameters: p_1 (right eye), p_2 (left eye), p_3 (nose), p_4 (mouth), p_5 (face), p_6 (right eyebrow), p_7 (left eyebrow).
Distance/size parameters: p_8 (face height), p_9 (face width), p_{10} (forehead height), p_{11} (forehead width), p_{12} (eye-eye), p_{13} (left eye-eyebrow), p_{14} (right eye-eyebrow), p_{15} (eye-nose), p_{16} (nose height), p_{17} (nose width), p_{18} (eye-mouth), p_{19} (mouth height),p_{20} (mouth width)

Normalization

$x_1 = p_1/p_5$	$x_7 = p_{12}/p_9$	$x_{13} = p_{14}/p_8$
$x_2 = p_2/p_5$	$x_8 = p_{15}/p_8$	$x_{14} = p_{19}/p_8$
$x_3 = p_3/p_5$	$x_9 = p_{18}/p_8$	$x_{15} = p_{20}/p_9$
$x_4 = p_4/p_5$	$x_{10} = p_{10}/p_8$	$x_{16} = p_{16}/p_8$
$x_5 = p_6/p_5$	$x_{11} = p_{11}/p_9$	$x_{17} = p_{17}/p_9$
$x_6 = p_7/p_5$	$x_{12} = p_{13}/p_8$	

被験者114 人の癒し構造
15歳-70歳 (日本人102人，外国人 12人，女性47人，男性67人)

研究の背景 ~HNNを用いた癒し解析システム～

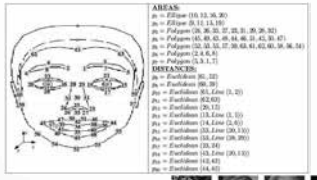

27

1
No Iyashi
2
A little
3
Iyashi

28

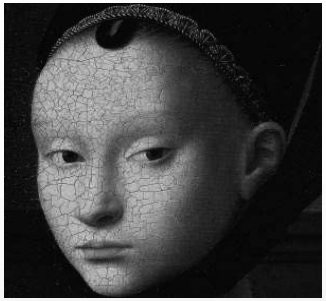

1 No Iyashi　2 A little　3 Iyashi

29

HNNのBNNに対する優位性（第2次AIブーム）。
HNNのLSTMに対する優位性（現在の第3次AIブーム／自動運転で）

❶ 1990年代から2010年あたりの第2次AIブームの際、
欠陥同定、最適化、表情分析全てでHNNのBNNに対し計算速度、精度とも優位性を示してきた。
❷ 更に因果が分かる唯一のものとしても評価されてきた
❸ BNNでは癒された(3)と分かっても何故か不明。因果が分かれば、どこで、どの様に判断してるかが分かる。
❹ このように因果が分かれば、癒されない(1)表情をどのようにすれば (3)になれるかが分かる。

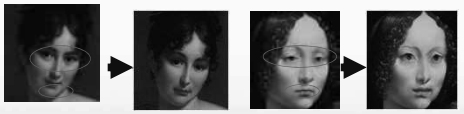

3 → 1　　1 → 3

❺ 自動運転レベル3（自動走行車が運転を担うが、危険察知の際、ドライバーに代わる）で重要なドライバーの時々刻々の集中度計測に利用。時系列に唯一利用できるとされるLSTM(Long Term Short Memory)に比し精度、リアルタイム性がはるかに優れることを示した論文投稿中。

30

第3次AIブームの到来）
自動運転への適用

自動運転の流れ
１３年の振返り

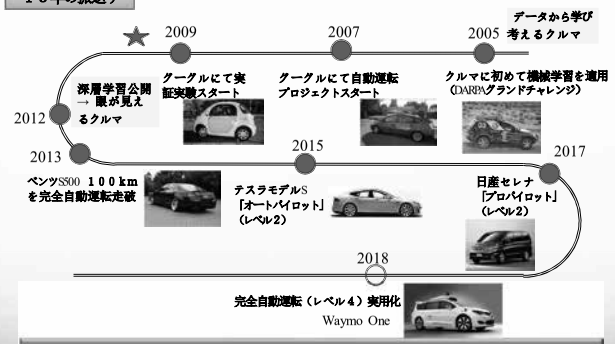

スタンフォード大学がクルマに初めて機械学習を取り入れたことが本格的な自動運転開発の始まり（2005年）→深層学習による画像認識で実用化の道が拓けた（2012年）

46

山崎雅史氏、クルマと自動車産業の現状と将来「100年に一度の大変革」時代、丸の内フォーラムより

3．自動運転の流れ
自動運転の流れを起こした人々
福島邦彦
１９８０年、ディープラーニングの原型となる新たな構造のニューラルネットワーク「ネオコグニトロン」を発表。
Sebastian Thrun
２００５年のDARPAロボットカーレースで優勝した「スタンレー」の開発者。後、グーグルに引き抜かれグーグルで自動運転プロジェクトを立ち上げた。
２０１５年
Fei Fei Li
１００万枚以上の画像からなる、世界で初めての「メガデータセット（イメージネット）」を構築。
Jeffery Hinton
２００６年、ディープラーニングの重要要素であるオートエンコーダーを考案。
２０１２年、「スーパービジョン」で画像認識エラー率１５%を達成しアルゴリズムをオープンソース化。
48
土台を築いた人々。成果を共有化した人。システムとしてまとめ上げた人。
山崎雅史氏、クルマと自動車産業の現状と将来「100年に一度の大変革」時代 丸の内フォーラムより

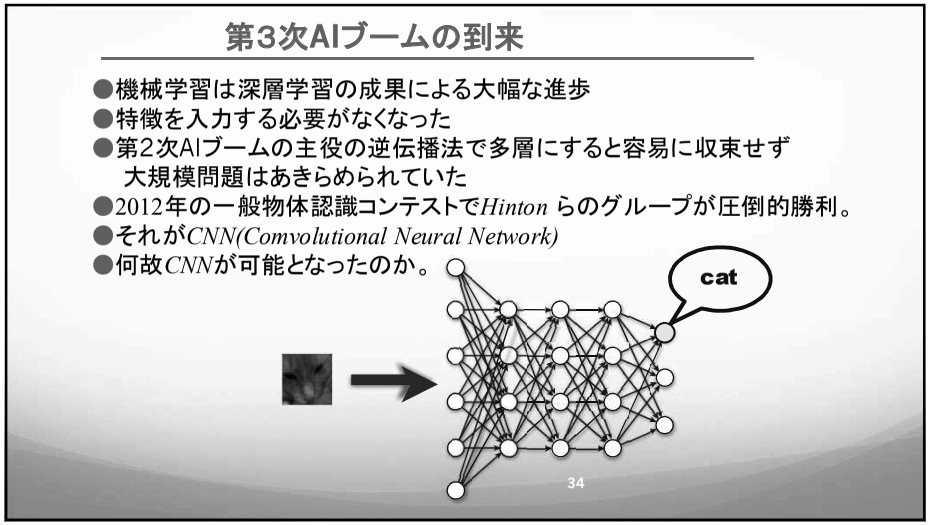
第3次AIブームの到来
●機械学習は深層学習の成果による大幅な進歩
●特徴を入力する必要がなくなった
●第2次AIブームの主役の逆伝播法で多層にすると容易に収束せず
大規模問題はあきらめられていた
●2012年の一般物体認識コンテストでHinton らのグループが圧倒的勝利。
●それがCNN(Comvolutional Neural Network)
●何故CNNが可能となったのか。
cat
34

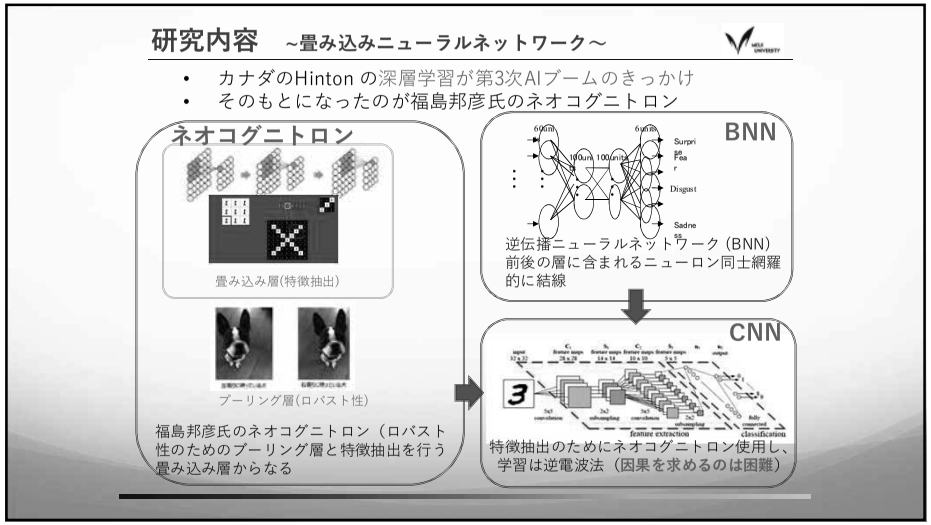
研究内容 ~畳み込みニューラルネットワーク~
• カナダのHinton の深層学習が第3次AIブームのきっかけ
• そのもとになったのが福島邦彦氏のネオコグニトロン
ネオコグニトロン
畳み込み層(特徴抽出)
プーリング層(ロバスト性)
福島邦彦氏のネオコグニトロン（ロバスト性のためのプーリング層と特徴抽出を行う畳み込み層からなる
BNN
逆伝播ニューラルネットワーク（BNN）
前後の層に含まれるニューロン同士網羅的に結線
CNN
特徴抽出のためにネオコグニトロン使用し、学習は逆電波法（因果を求めるのは困難）

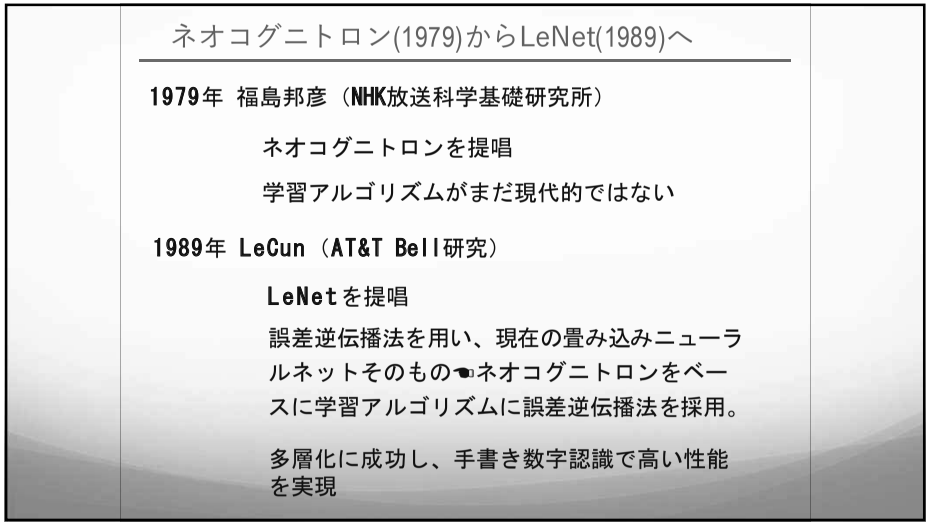
ネオコグニトロン(1979)からLeNet(1989)へ
1979年 福島邦彦（NHK放送科学基礎研究所）
ネオコグニトロンを提唱
学習アルゴリズムがまだ現代的ではない
1989年 LeCun（AT&T Bell研究）
LeNetを提唱
誤差逆伝播法を用い、現在の畳み込みニューラルネットそのものネオコグニトロンをベースに学習アルゴリズムに誤差逆伝播法を採用。
多層化に成功し、手書き数字認識で高い性能を実現

畳み込みニューラルネット(CNN)のための工夫

勾配消失の回避

活性化関数：シグモイド関数からLeRUなどより簡単なものとする。

事前学習・転移学習を用いる

GPGPU（general purpose graphics processing unit）での並列化

過学習の抑制

学習用データの大規模化、高品質化、標準化、水増し

ドロップアウトなどの正則化

アーキテクチャの工夫

因果の分かる機械学習とはどういうものか

それは、ホログラフィックニューラルネットワークをベースとするもの

（複素領域に写像された出力ベクトル）＝（複素領域に写像された入力ベクトル）[システムの伝達関数]

J.G.Sutherland, The Holographic Model of Memory, Learning and Expression, International Journal of Neural System, 1990, Vol.1 No.3, 259

HNNの歴史

第2次ブームの代表的な逆伝播法にFQHNN
（ファジイ推論第2類組込みHNN）は優ることを確信していた。

カナダのJ.G.Sutherlandが始める／1990年

萩原　伝達関数の逆行列の求め方検討／ムーアペンローズからの脱却＆新しい応用開拓／1998年以降

38

Khan：写像関数の検討／1998年

ルイス＆萩原：　ファジイ推論第Ⅱ類で得られる重みを入力の重みとするFQHNNによって問題に応じて重み係数が正しく求められるようになった／2011年

FQHNN – Previous Works

Sutherland 1990

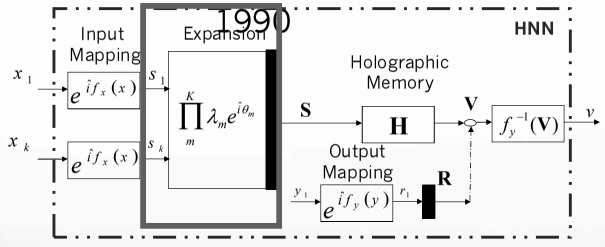

Higher Order Statistics

$$\mathbf{H} = (\mathbf{S}^* \cdot \mathbf{S})^{-1} \cdot \mathbf{S}^* \cdot \mathbf{R}.$$

U unused during the training is predicted by

$$\mathbf{V} = \mathbf{U} \cdot \mathbf{H}.$$

ファジイ推論組込みホログラフィックニューラルネットワーク-

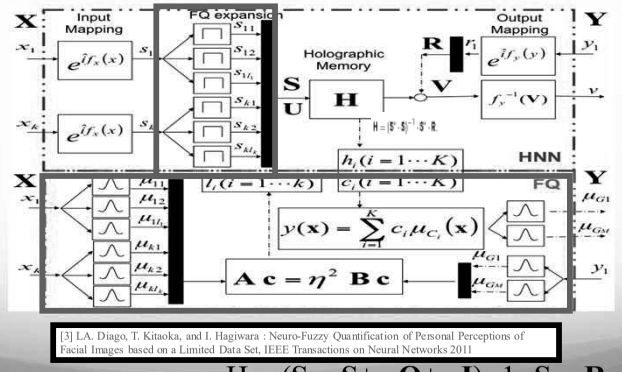

[3] LA. Diago, T. Kitaoka, and I. Hagiwara : Neuro-Fuzzy Quantification of Personal Perceptions of Facial Images based on a Limited Data Set, IEEE Transactions on Neural Networks 2011

$$\mathbf{H} = (\mathbf{S}* \cdot \mathbf{S} + \rho_1 \mathbf{O} + \rho_2 \mathbf{I}) - 1 \cdot \mathbf{S}* \cdot \mathbf{R}$$

CNN vs HNN - ImageNet

CIFAR-10 dataset - 60000 32x32 color images in 10 classes

多層型の、畳み込みニューラルネットワークCNN(Convolutional Neural Network): は様々なバージョンに発展し、ディープラーニングの主役を演じている。一方、講演者のグループではラプラス変換を拡張したホログラフィックニューラルネットワーク(HNN)で進めている。飛行機、自動車、鳥、猫、鹿、犬、カエル、馬、船、トラックの計10種類6万枚位の画像で学習し、CNNでは下図のように発散するところ、HNNで90%以上の正答率が得られた。

CNN

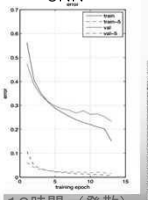

10時間（発散）

HNN Test_error = 9.147%
10分程度

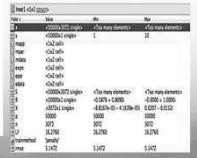

画像認識：複数人の顔表情のリアルタイム抽出と脳波比較

深層学習を用いて、６基本表情から負の表情を抽出し、疲労度や散漫度を測定する

６基本表情　顔表情から状態の抽出

快適介護空間と自動走行車との関連性

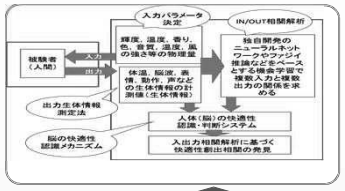

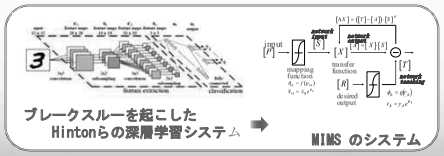

ブレークスルーを起こした
Hintonらの深層学習システム

MIMS のシステム

単路走行でのユースケース

システムはドライバーの運転不得意分野を抽出
- 道路の中央を走れない
- 左右にふらふら揺らいで走行
- 周囲の車両・歩行者に不注意
- 速度超過
- 障害物回避が危うい

システムは状況に応じて以下の処理を行う
- ドライバに運転のアドバイス
- ドライバの不十分な操作を補う補助制御
  ～ふらふらを抑える制御
  ～車線中央を走行する制御など
- ドライバの運転にオーバーライドして緊急回避操作

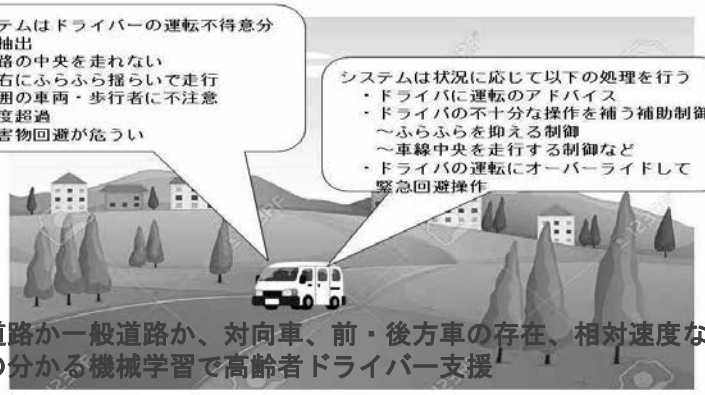

山岳道路か一般道路か、対向車、前・後方車の存在、相対速度など因果の分かる機械学習で高齢者ドライバー支援

安全安心・乗り心地向上技術

ドライブレコーダーから独自のリアルタイム最適制御で事故回避モデルの構築。解析モデルでパラメーターを変え深層学習のデータベースに

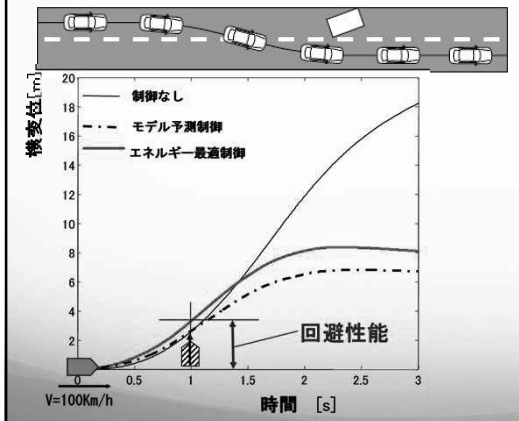

緊急回避性能シミュレーション結果(横変位)

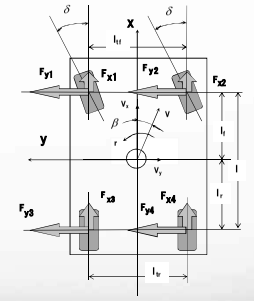

車両モデル

ドライブレコーダーから独自のリアルタイム最適制御で事故回避モデルの構築。解析モデルでパラメーターを変え深層学習のデータベースに

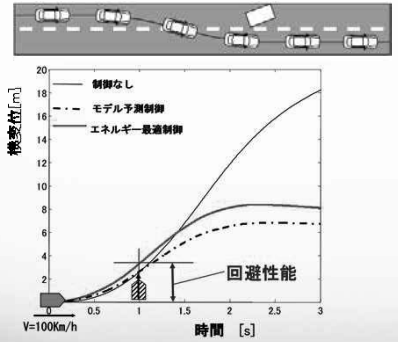

緊急回避性能シミュレーション結果(横変位)

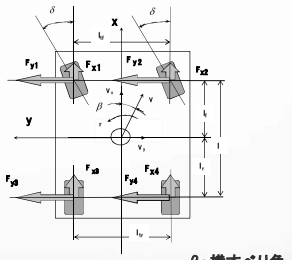

m : 車両質量
I_z : ヨー慣性モーメント

β : 横すべり角
δ : 前輪舵角
V: 車速
r: ヨーレート

車両モデル

緊急回避性能シミュレーション結果(横速度)

- 安定性の目安である横速度は±3m/s以下にしっかり抑えられており安定性を確保.

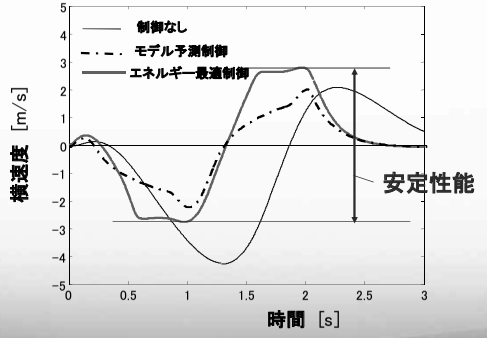

図10 緊急回避性能シミュレーション結果(横速度)

緊急回避性能シミュレーション結果（前輪舵角）

- 初期の大舵角により目標値よりも大きいヨーレートを発生させた後，舵角が横速度に大きい影響を与える前に逆操舵しあたかもプロドライバーがカウンターステア(あて舵)で横速度を過大に発生することを防ぐような効果を実現⇒エネルギー最適制御は緊急回避レーンチェンジ時に創発的な操舵により大きい横変位を発生させながらも車両安定性を向上させていることがシミュレーションにより確認
- 創発ともいえる操舵が可能：，L関数の中にパワー形式の仮想物理量を導入したことによる．この意味は現在のヨーレートを目標ヨーレートに変化させるのに必要なパワーであるがこれは現実のパワーではなく仮想的パワーである

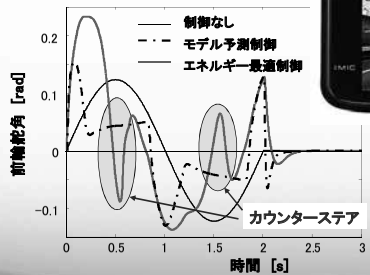

ドライブレコーダー評価

図11 緊急回避性能シミュレーション結果（前輪舵角）

緊急回避性能シミュレーション結果（ヨーモーメント）

$$u = k\left\{M - (\hat{r} - r)\frac{\partial M}{\partial r}\right\}$$

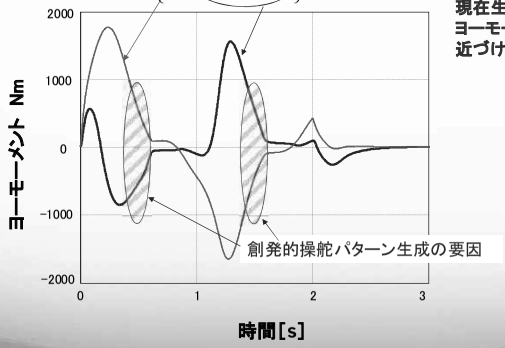

現在生じているタイヤのヨーモーメントに抗して目標値に近づける作用が生じる．

- プロドライバー操舵特性の変分原理表現イメージ⇒どのような評価関数を創るかといった評価関数創成理論と関係

仮想パワー

$$L = r_i(\hat{r} - r)M + r_a u r$$

$$\int \frac{\partial L}{\partial q}dt - \frac{\partial L}{\partial \dot{q}} + \frac{d}{dt}\left(\frac{\partial L}{\partial \dot{q}}\right) = 0$$

$$u = k\left\{-(\hat{r} - r)\frac{\partial M}{\partial r} + M\right\}$$

プロドライバーの操舵特性

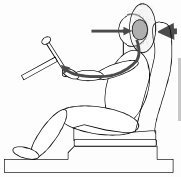

プロドライバの運動中枢はモーメント線図を把握して操舵している

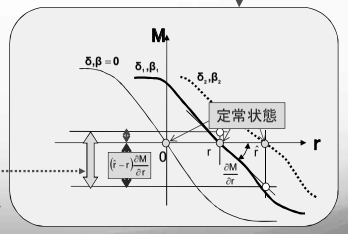

プロドライバー操舵特性の変分原理表現イメージ

新しい最適制御理論位置付け：
リアルタイムで唯一つ対応が可能なエネルギー最適制御

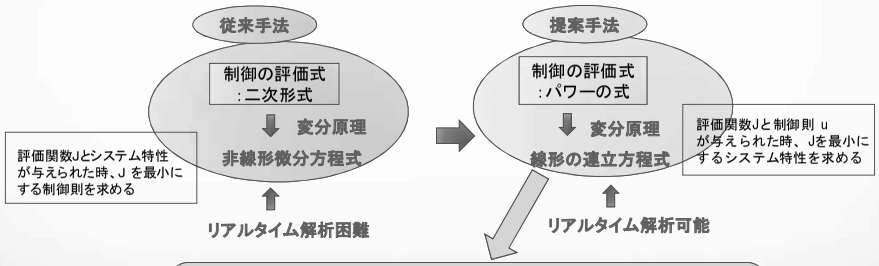

日本応用数理学会：招待論文
IEEEジャーナル論文などに掲載
日本自動車技術会論文賞：ハイブリッド電気自動車のエネルギーフロー制御に関して多くの企業との共同研究

本日のまとめ

❶ 自動車産業における機械学習の利用のきっかけ

❷ 現在主流のCNNについて

❸ 因果のわかる機械学習について

❹ 明治大学の地方創生の取組について

シーズ情報1／高齢者ドライバー援用協調制御など自動走行車への機械学習適用研究

自動車への機械学習の適用は、2005年のスタンフォード大の適用から始まる。大手自動車会社では多大な人・物・金を使い自動走行車への機械学習の適用を試みるもさほど進展は見られない。自動走行車にはレベルゼロからレベル5まである。現在漸くレベル2の車両が販売されている。レベル3は、自動走行車が基本的に運転するも、自動走行車で対応できないシーンで運転者に運転を委ねるというものであるが、これが可能かという議論もある。現在、カナダのHinton らが始めた深層学習のおかげでAI第3時代と言われている。これはよく見ると、日本の福島邦彦氏のネオコグニトロンをベースに学習の更新は逆伝播法でなされており良く言われているのが「結構当たるがなぜ当たるのか不明」。すなわち因果が分からない。レベル3の場合、リラックスしている運転者に急に変われと言ってもそれは無理で、「何故変わって欲しいのか、何をしてもらいたいのか」を明確にして始めて可能。それには因果が分かる機械学習が必須。我々の因果の分かるニューラルネットワークを利用しHinton らの深層学習技術を駆逐して始めて真の自動走行車の実現が可能となる。これに関してコラボする数理科学者を是非お願いしたい。詳細は省くが、これが可能となれば現在悲惨な状況が絶えない高齢者ドライバーの事故を防ぐ「高齢者ドライバー援用協調制御」も可能となる。

6基本表情認識用ニューラルネットワーク

シーズ情報2／リアルタイムに得られるエネルギー最適制御

現在自動車には本来取り入れられるべき最適制御は搭載されていない。ハミルトンの式に変分原理を施す現在主流の最適制御では非線形の微分方程式が得られリアルタイムでは解けないからである。そこで予測制御等が利用されている。これまでの「二次形式の評価関数Jとシステム特性が与えられた時、J を最小にする制御則を求める」考えから、「パワーの式を使用する評価関数Jと制御則 uが与えられた時、Jを最小にするシステム特性を求める」との発想の転換により、リアルタイムで解けることとなった。「エネルギー最適制御と銘打って論文投稿するも悉くリジェクトされたが、某自動車メーカーの技術者が「最適制御かどうかは知らない。我々にとって最適な制御はこれまで解けなかったことが解ける制御則と宣伝して下さり、それから風向きが変わり、國際誌ジャーナル掲載、自動車技術会論文賞、応用数理学会招待論文2編が得られている。ただ、其の使用は広まっていない。それは評価関数Jの中に仮想のパワーの式も必要とするかである。例えばベテランドライバーの操作を参考に仮想のパワー式を作成すると当に創発的ともいえる優れた挙動が得られる。この仮想式の選び方を数理的に明らかにすると汎用性が得られる。これに関するべくコラボを願いたい。

6基本表情認識用ニューラルネットワーク

自動運転のヒューマンファクター
ドライバー状態と安全な運転引継ぎのための検討

○北﨑　智之（国立研究開発法人 産業技術総合研究所）

Human factors in automated driving
Investigation into the relation between driver states and safe takeovers.

* S. Kitazaki (National Institute of Advanced Industrial Science and Technology, AIST)

Abstract－ One of the expectations towards the automated driving technology is dramatic reduction of road crashes. The background hypothesis is that replacing the human driver by a computer will eliminate crashes that are currently caused by human errors. However, complication of the systems and new tasks imposed on the driver may generate new risks, system-induced problems. The main focus of human factors research in automated driving is to reduce the system-induced problems. The research project was conducted from FY2016 to FY2018 with the funding awarded by Cabinet Office and SIP-adus Phase 1. One of the three tasks of the project aimed at understanding effects of cognitive states of the driver on his/her takeover performance and extracting metrics of the influential driver states for driver monitoring systems. It was found that different driver states influenced takeover performance in different ways. Some metrics for the influencing states were identified. These findings are being discussed and applied to International Standards.

Index terms－ Automated driving, human factors, safety, driver state, readiness, takeover, ISO

1. BACK GROUND

The number of deaths on roads in Japan has been decreasing since the beginning of 1990s, thanks to improved vehicle safety, improved road infrastructure, and also legal reformations. However, the speed of decrement appears to be smaller since late 2000s (Fig.1). The Government of Japan set strategic goals as 2500 deaths by 2020 and 0 death by 2030. In order to achieve the goals, the decrement curve needs another turning point that brings the curve into a steep decrement. It is known that more than 90% of on-road crashes are caused by human errors. Therefore, replacing the "human driver" by a computer is assumed to be a solution and the automated driving technology is expected to produce a dramatic turning point.

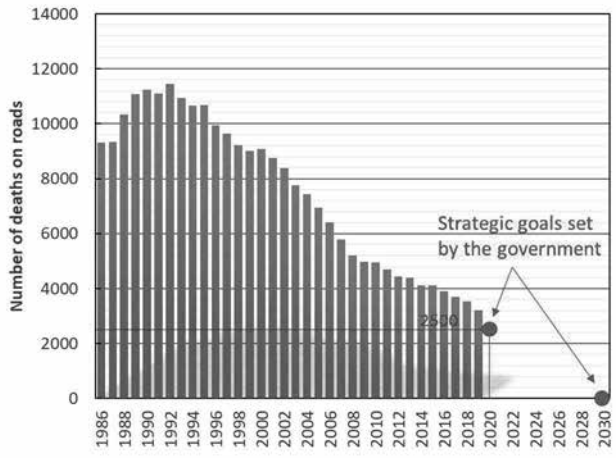

Fig. 1 The number of deaths on roads in Japan[(1)]

Various Advanced Driver Assistant Systems (ADAS) have been developed and launched into the market since the middle 1990s. ADAS can be categorized as driver monitoring, information-based driver assistance, and automation-based driver assistance. The automation-based driver assistance can be further categorized as assistance to compensate human inability and partial replacement of the driving task. Each category of ADAS has different operational time domain while automated driving (SAE Level 2-Level 5)[2)] covers all the time domains before pre-crash (Fig.2).

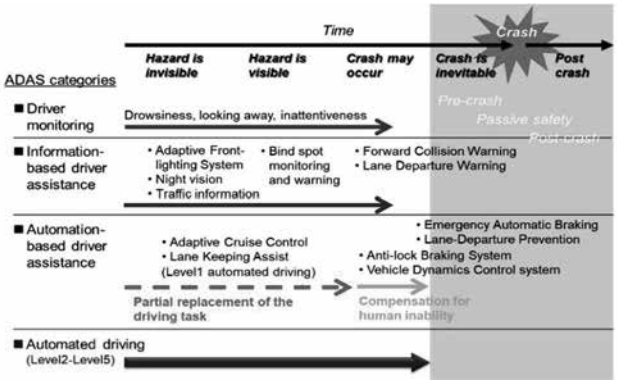

Fig. 2 ADAS categories and automated driving, and their conceptual operational time domains.

Driver monitoring systems give an alert to the driver when they detect unsafe states of the driver such as drowsiness, looking away and inattentiveness. Information-based driver assistance supports the driver by reinforcing visibility of the environment or providing information of visible and invisible objects or events. Compensation for human inability of automation-based assistance supports the driver by functions beyond human abilities to avoid/mitigate a crash. The systems in this category have been validated their effectiveness for safety and widely adopted in many products.

Partial replacement of the driving task by automation-based assistance can cause system-induced problems such as over-trust, over-reliance and mis-use when the system is designed inappropriately. Systems such as ACC and LKA (Level 1 systems) have been designed carefully to avoid the problems. However, automated driving systems of Level 2 and Level 3 will be much more complicated and may have potential risk of magnified system-induced problems. Moreover, Level 2 and Level 3 systems impose on the driver new tasks such as the Object and Event Detection and Response (OEDR) without manual operations and taking-over the driving task from the system within a limited time. Complication of the systems and the new tasks to the driver may generate another system-induced risk.

Considering the above, reduction of deaths on roads will be expressed by a simple equation (1). The aim of Human Factors research is to minimize (hopefully eliminate) the second term in Equation (1). To minimize the second term, first, we need to know limitation of human ability in use of the systems. Second, based on understanding of limitation of human ability, requirements to the system need to be clarified from human-centered perspective. Third, interventions to maximize the human ability need to be developed. The interventions include Human-Machine -Interfaces (HMIs) and also education and training of users (i.e. drivers).

[Reduction of deaths on roads]
＝[Reduction of crashes caused by the human errors]
－[New crashes generated by the system-induces problems]
•••• (1)

2. RESEARCH PROJECT

The research project on human factors in automated driving was conducted by a consortium with members in academia and industry. The consortium consisted of AIST (National Institute of Industrial Science and Technology), University of Tsukuba, Keio University, DENSO Co., Ltd., and Tokyoto Business Service Co., Ltd. (Fig. 3). The project was funded by Cabinet Office and SIP-adus (Strategic Innovation Promotion Program-Automated Driving for Universal Services) Phase 1 for FY2016 to FY2018.

Fig. 3 The research consortium for the project.

First, potential problems related to human factors in automated driving were extracted using the framework with three interactions; interactions between driver and the system, between the system and surrounding road users and between the system and the society (Fig. 4).

Extracted potential problems were classified between those in the cooperative field and the competitive field among the developers in the industry. Then, the problems in the cooperative field were prioritized. Three problems with the highest priority in the cooperative field were set as the three tasks A, B and C for the project.

- Task A investigated effects of system information (knowledge and dynamic state of the system) on drivers' takeover performance for Levels 2 &3.
- Task B investigated effects of driver state (readiness) on his/her takeover performance for Levels 2 & 3 and extracted metrics of readiness for driver monitoring.
- Task C investigated effective ways to functionalize the automated vehicle to communicate surrounding road users for higher Levels 2 & above.

Fig. 4 The framework used to extract potential problems related to human factors in automated driving.

3. OVERVIEW OF TASK B AND RESEARCH AIMS

This report focuses on Task B. With the Level 2 system, the driver is expected to perform the OEDR (Object and Event Detection and Response) task all the time and expected to takeover immediately when the system requests. With the Level 3 system, the driver may be allowed to perform some non-driving related activities but expected to takeover within the designed transition time when the system requests. When driver state is not ideal in the physical or cognitive dimensions, the takeover action may be delayed or its quality may decline[(3) - (15)].

One of the solutions for unsafe takeovers is considered to be the Driver Monitoring System (DMS). The concept of DMS is the system that monitors driver state all the time in terms of readiness (i.e. readiness to takeover) and detects declined readiness to inform the main system. The main system, then, executes intervention(s) which is either an alert and/or termination of automated mode to improve the declined readiness or stopping the vehicle when continuation of driving is at high risk (Fig. 5).

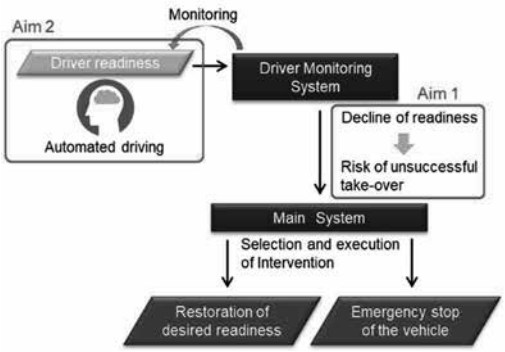

Fig. 5 The concept of the driver monitoring system and research aims of Task B.

There were two aims in this task. Aim 1 was to investigate effects of various types of driver state on takeover performance and define readiness as influential states. Aim 2 was to extract metrics of readiness for DMS.

Readiness was defined as driver's dynamic state during automated driving, which influences takeover performance of the driver[16]. Readiness was considered to include both physical state and visual-cognitive state of the driver. The physical state might include position of hands, posture, seating position and others but they were not included in this task because the effects and metrics were both relatively apparent. Visual-cognitive state was classified as cognitively loaded, visually loaded and low arousal and their effects on takeover performance and metrics were investigated. The takeover performance included not only speed of the response but also quality of actions to manually cope with an object/event after the takeover.

4. METHODS

Both aim 1 and aim 2 were included in Experiment 1 and Experiment 2. A total of 80 subjects participated in the experiments. The experiments used the motion-base driving simulator located at National Institute of Advanced Industrial Science and Technology (Fig.6). The experiments were approved by IRB of AIST and informed consents were obtained from all the subjects.

4. 1 Experiment 1

The subjects drove the Level 2 system implemented in the driving simulator with non-driving related tasks (NDRTs) and without a NDRT while the system was functioning. The NDRTs were cognitive tasks (low and high loads) using the N-back Tasks[17] and visual tasks (low and high loads) using the SuRTs[18]. The subjects were instructed to place their hands off the steering wheel, and monitor the environment as well as the system while performing the NDRT. Various physiological indices of the subjects were measured while driving (Table 1).

The scenario included several events with low criticality for which the system requests takeover to the subject. One of the events was used for measuring takeover performance. The event was the situation where the subject vehicle was following a leading vehicle with the system functioning, the Request to Intervene (RtI) was issued due to a malfunction of the system and the system shut down, the leading vehicle changed the lane 1s after the RtI onset and exposed a stationary broken-down vehicle in the same lane. The RtI was issued when Time To Collision (TTC) was 6s to the broken-down vehicle. The subject was expected to takeover in response to RtI, detect the stationary vehicle, change the lane manually, and finally stabilize the own vehicle in the neighboring lane. Various performance measures were collected in terms of response to RtI, maneuvering to change lane and avoid crash, and stabilization of the vehicle after changing lane.

4.2 Experiment 2

For investigating effects of arousal, the subjects drove the Level 3 system through another scenario. The subjects were not given any tasks including monitoring the environment and the system, expecting the monotony would induce drowsiness of the subjects with enough inter-subject variability. Physiological indices shown in Table 1 were also measured in Experiment 2. The scenario was monotonous 20 minutes motorway drive and included an event of exiting the motorway after issuing RtI at the end of the scenario. The time to initiate steering maneuver in response to RtI was used as the performance measure.

Fig. 6 The driving simulator at AIST used for the Task B experiments.

Table 1 Physiological measurements

Physiological measurements
EEG (Event-Related Potentials)
Visual behavior
Saccadic movements of the eyes
Pupil diameter
Blinking frequency
Perclos
Hear rate
Blood pressure

5. RESULTS

The level of cognitive load given to the subjects while the system was functioning correlated with minimum distance to the stationary vehicle while changing lane after RtI (Fig. 7). The result implied that the effect of the cognitive load remained after RtI and the cognitive process stayed slowed down resulting in degradation of driver's performance to avoid collision with the object. On the other hand, the level

of visual load correlated with variability in steering angle at 5s after changing lane (Fig.8). The result implied that the visual load degraded the situation awareness of the driver resulting in abrupt steering and unstable steering operation to stabilize the vehicle after changing lane. There was no difference found in the response times for steering initiation between the two loading conditions. The schematic expression of the vehicle trajectories in the two loading conditions is shown in Fig.9.

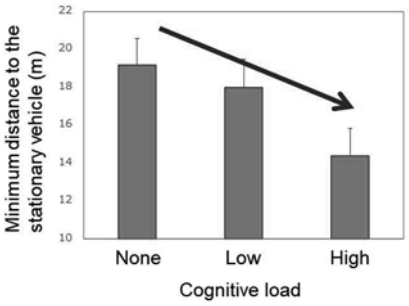

Fig. 7 Cognitive load given to the driver before RtI and takeover performance after RtI.

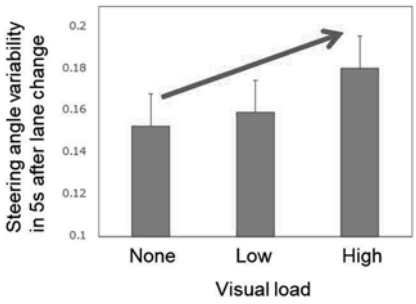

Fig. 8 Visual load given to the driver before RtI and takeover performance after RtI.

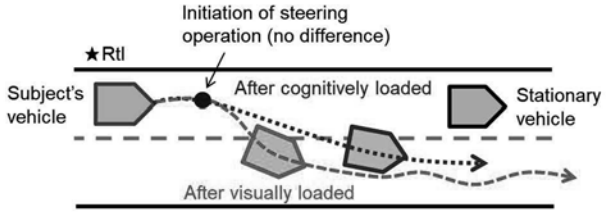

Fig. 9 Schematic expression of trajectories of the subject's vehicle after RtI.

Multiple biometrics of the cognitive and visual states of the driver (readiness) were extracted. Considering in-vehicle real-time monitoring of readiness by DMS, blinking frequency and frequency of saccadic eye movement were candidate metrics for cognitively loaded state (Fig.10), while percent time of forward looking and frequency of saccadic eye movement were those for visually loaded state (Fig.11). For arousal level, Perclos[19] was found to correlate with the time to initiate steering operation to exit the motorway after RtI (Fig.12).

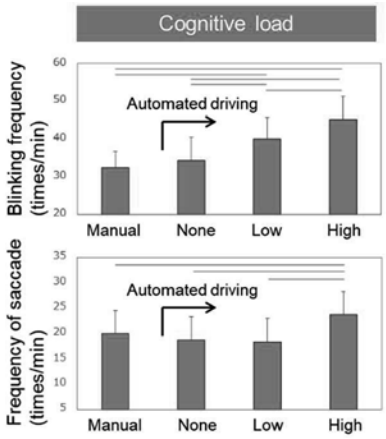

Fig. 10 Cognitively loaded driver state and biometrics

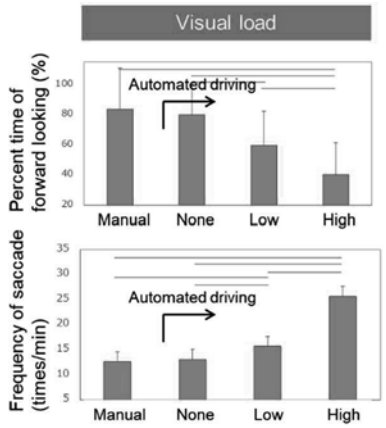

Fig. 11 Visually loaded driver state and biometrics.

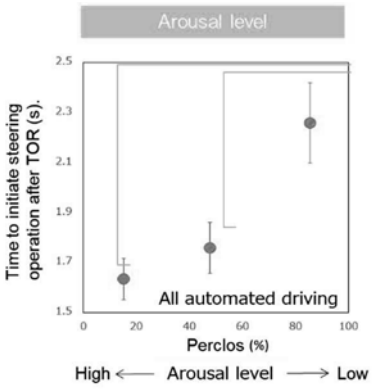

Fig. 12 Perclos measured before RtI and takeover performance after RtI.

6. CONCLUSIONS OF TASK B

First, low arousal, cognitively loaded and visually loaded states of the driver degraded driver's take-over performance in different ways. They were found to be components of readiness. Second, frequency of the saccadic movements of the eyes, blinking frequency, percent time of forward look-

ing, and Perclos were extracted as metrics of readiness for driver monitoring.

7. DOMESTIC AND INTERNATIONAL COMMUNICATOIONS AND COLLABORATIONS

The progress and findings of the project were reported regularly to the management of SIP-adus (Fug.13). The research consortium had been communicating with JSAE (Society of Automotive Engineers of Japan) and JAMA (Japan Automotive Manufacturers Association) on monthly base to apply findings of the project and navigate the project to link to international standardization, UN-ECE regulation and domestic guidelines. The findings of the project had been widely shared with engineers and researchers in the industry and academia and government officials through annual SIP-adus Workshops as well as independent annual symposiums on the project.

The consortium has been internationally communicating about project plans and findings with Human Factors experts in EU and US based on the US-EU-JP Trilateral Cooperation framework and also with experts in Germany based on the Germany-Japan Bilateral Cooperation framework.

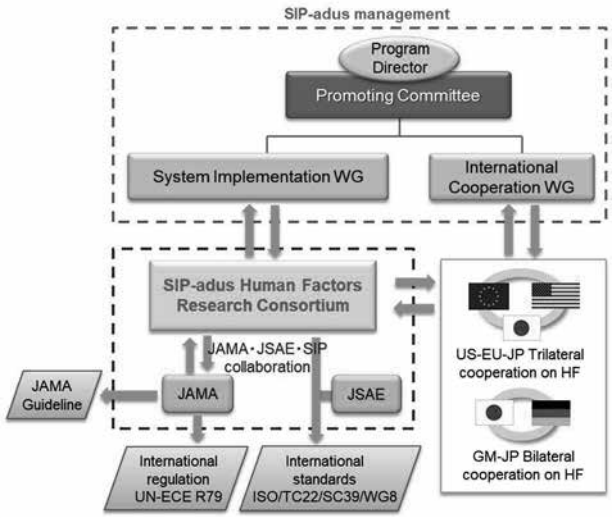

Fig. 13 Domestic and international communications and collaborations.

8. INTERNATIONAL STANDARDIZATION

The project members had been working with Human Interface Working Group at JSAE to apply the findings to standards at ISO/TC22/SC39/WG8. Some of the findings in Task A and Task B were included in ISO TR21959-1[20] "Road vehicles - Human performance and state in the context of automated driving - Part 1: Common underlying concepts" and TR21959-2[16] "Road vehicles - Human performance and state in the context of automated driving - Part 2: Considerations in designing experiments to investigate transition processes". Both TR21959-1 and TR21959-2 were led by Japanese delegates. The main findings in Task B are now being discussed and applied to on-going ISO TS5283 "Ergonomic aspects of driver monitoring and system interventions" which is also led by a Japanese delegate. Findings in Task C is being discussed and applied to on-going ISO TR23735 "Road Vehicles – Ergonomic design guidance for external visual communication from automated vehicles to other road users" which is led by a US delegate.

9. GENERAL CONCLUSIONS

The research project on human factors in automated driving was conducted from FY2016 to FY2018 with the funding awarded by Cabinet Office and SIP-adus Phase 1. The project focused on minimizing the system-induced problems to enhance safety of Level 2 and Level 3 automated driving systems. Three tasks A, B and C were set as those with high priority in the cooperative field among the developers in the industry. This report focused on Task B where effects of cognitive states of the driver on his/her takeover performance were experimentally demonstrated. The Task B also extracted metrics of such cognitive states of the driver. These findings are being discussed and applied to International Standards.

REFERENCES

1) Department of Transportation Planning Division, National Police Agency Japan (2019). Number of victims in on-road crashes in 2019.
2) SAE J3016 (2016, 2018), Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicle.
3) Carsten, O., Lai, F. C. H., Barnard, Y., Jamson, a. H., and Merat, N. (2012). Control task substitution in semi-automated driving: Does it matter what aspects are automated? Human Factors, 54(5), 747-761.
4) Young, M. S., & Stanton, N. A. (2002a). Malleable attentional resources theory: a new explanation for the effects of mental underload on performance. Human factors, 44(3), 365-375.
5) Young, M. S. and Stanton, N. A. (2002b). Attention and automation: new perspectives on mental underload and performance. Theoretical issues in ergonomics science, 3(2), 178-194.
6) Radlmayr, J., Gold, C., Lorenz, L., Farid, M., & Bengler, K. (2014, September). How traffic situations and non-driving related tasks affect the take-over quality in highly automated driving. In Proceedings of the human factors and ergonomics society annual meeting (Vol. 58, No. 1, pp. 2063-2067). Sage CA: Los Angeles, CA: Sage Publications.
7) Schömig, N., Hargutt, V., Neukum, A., Petermann-Stock, I., and Othersen, I. (2015). The interaction between highly automated driving and the development of drowsiness. Procedia Manufacturing, 3, 6652-6659.
8) Zeeb, K., Buchner, A., and Schrauf, M. (2015). What determines the take-over time? An integrated model approach of driver take-over after automated driving. Accident Analysis & Prevention, 78, 212-221.
9) Gonçalves, J., Happee, R., and Bengler, K. (2016). Drowsiness in conditional automation: proneness, diagnosis and driving performance effects. In 2016 IEEE

19th International Conference on Intelli-gent Transportation Systems (ITSC) (pp. 873-878). IEEE.
10) Zeeb, K., Buchner, A., and Schrauf, M. (2016). Is take-over time all that matters? The impact of visual-cognitive load on driver take-over quality after conditionally automated driving. Accident analysis & prevention, 92, 230-239.
11) Yang, Y., Gerlicher, M., and Bengler, K. (2018). How does relaxing posture influence take-over performance in an automated vehicle?. In Proceedings of the Human Factors and Ergonomics Society Annual Meeting (Vol. 62, No. 1, pp. 696-700). Sage CA: Los Angeles, CA: SAGE Publications.
12) Gold, C., Happee, R., & Bengler, K. (2018). Modeling take-over performance in level 3 conditionally automated vehicles. Accident Analysis & Prevention, 116, 3-13.
13) Wandtner, B., Schomig, N., and Schmidt, G. (2018). Effects of non-driving related task modalities on takeover performance in highly automated driving. Human factors, 60(6), 870-881.
14) Zhang, B., de Winter, J., Varotto, S., Happee, R., and Martens, M. (2019). Determinants of take-over time from automated driving: A meta-analysis of 129 studies. Transportation Research Part F: Traffic Psychology and Behaviour, 64, 285-307.
15) Choi, D., Sato, T., Ando, T., Abe, T., Akamatsu, M., and Kitazaki, S. (2020). Effects of cognitive and visual loads on driving performance after take-over request (TOR) in automated driving. Applied Ergonomics 85, 103074.
16) International Organization for Standardization (2020). ISO TR21959-2 Road vehicles — Human performance and state in the context of automated driving — Part 2: Considerations in designing experiments to investigate transition processes.
17) Kirchner, W. K. (1958). Age differences in short-term retention of rapidly changing information. Journal of Experimental Psychology, 55(1), 352-358.
18) International Organization for Standardization (2019). ISO TS14198 Road vehicles — Ergonomic aspects of transport information and control systems — Calibration tasks for methods which assess driver demand due to the use of in-vehicle systems.
19) Dinges, D. F. and Grace, R. (1998). PERCLOS: A Valid Psychophysiological Measure of Alertness as Assessed by Psychomotor Vigilance. Federal Highway Administration, Office of Motor Carrier Research and Standards; Washington, DC, USA.
20) International Organization for Standardization (2020). ISO TR21959-1 Road vehicles - Human performance and state in the context of automated driving - Part 1: Common underlying concepts.

自動運転のヒューマンファクター

ドライバー状態と安全な運転引継ぎのための検討

国立研究開発法人 産業技術総合研究所
ヒューマンモビリティ―研究センター
北﨑智之

自動運転車の社会的価値

- ✓ 交通事故の削減
- ✓ 交通渋滞緩和
- ✓ 環境負荷低減
- ✓ 職業ドライバー不足の解消
- ✓ 高齢者や障害者の新しいモビリティ
- ✓ 新しい街づくり

など

自動運転車の社会的価値

- ✓ 交通事故の削減
- ✓ 交通渋滞緩和
- ✓ 環境負荷低減
- ✓ 職業ドライバー不足の解消
- ✓ 高齢者や障害者の新しいモビリティ
- ✓ 新しい街づくり

など

交通事故の人的要因別事故割合

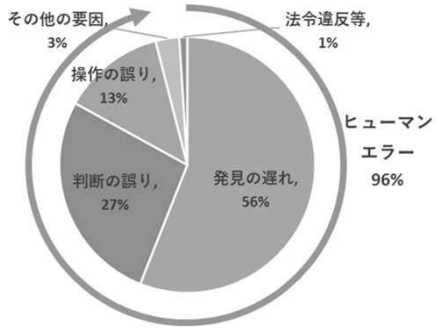

平成23年交通事故統計表データ
（公財）交通事故総合分析センター
国土交通省資料より抜粋（高速道路の事故データ）

SAE J3016 (2016)による自動運転レベルの定義

- **レベル0**　※ADAS
  手動運転（警報は含む）.
- **レベル1**　※ADAS
  限られた条件内での車両の縦方向もしくは横方向どちらかの自動化．ドライバーには常に監視責任が伴う.
- **レベル2**　※当面の開発ターゲット
  限られた条件内での車両の縦横同時自動化．ただしドライバーには**常に監視責任**が伴う.
- **レベル3**　※次の開発ターゲット
  限られた条件内での車両の縦横同時自動化．システム作動中は，ドライバーには監視責任がないが，**システムからの運転引継ぎ要請に応えられる状態**になければならない.
- **レベル4**
  限られた条件内での車両の縦横同時自動化．システム作動中は，ドライバーには監視責任がなく．システムからの運転引継ぎ要請も発生しない.
- **レベル5**
  条件なしの車両の縦横同時自動化．システム作動中は，ドライバーには監視責任がなく，システムからの運転引継ぎ要請も発生しない.

技術開発の道のりと関連事故

官民 ITS 構想・ロードマップ 2018

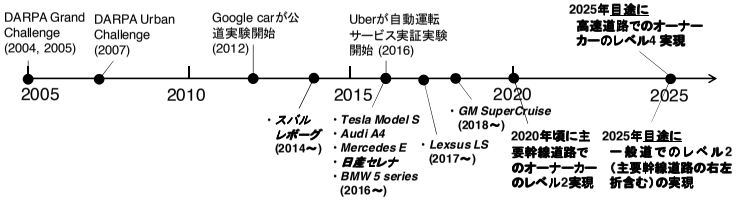

運転支援と自動運転　事故削減と新たな事故の懸念

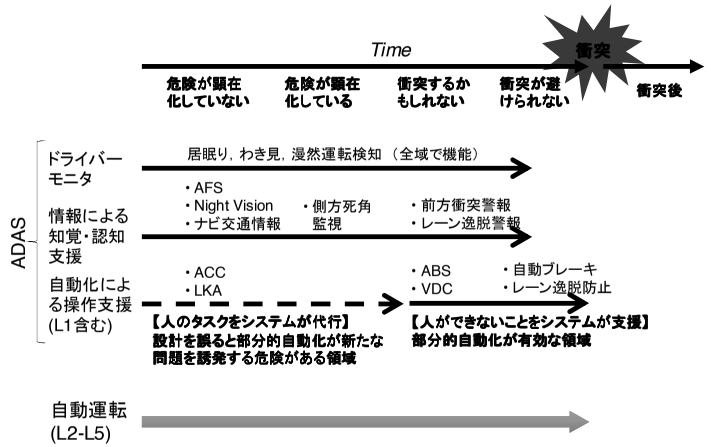

運転支援と自動運転　事故削減と新たな事故の懸念

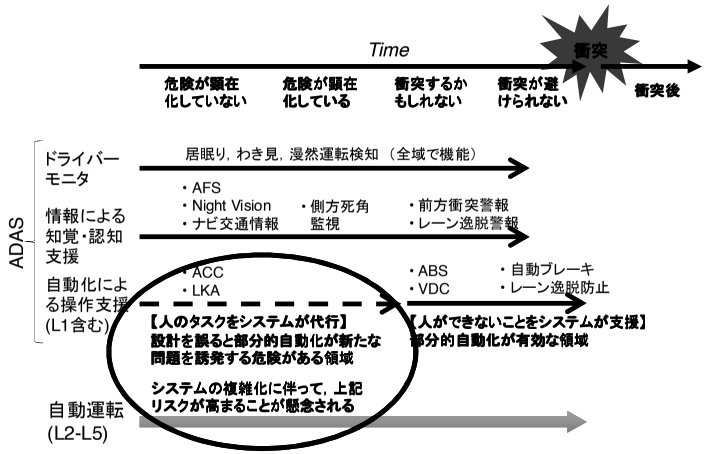

自動運転のヒューマンファクター課題の位置づけ

自動運転による事故の削減 ＝ 通常運転におけるヒューマンエラー／人の機能限界に起因する事故の削減 － 自動運転に起因する新たな事故の発生

- ドライバーの能力限界
- システム機能の不理解，過信，誤審，混乱
- リスクホメオスタシス etc.

これを排除することが自動運転のヒューマンファクター課題

システムの機能限界とドライバーの監視責任

Tesla最初の死亡事故

Tesla Model S Autopilot 2016年5月7日米国フロリダ州

自動運転からの運転引継ぎの難しさ

Joshua Brown, Autopilot Saves Model S, downloaded from Youtube on April 22, 2016.
https://www.youtube.com/watch?v=9I5rraWJq6E

Video

監視タスクの難しさ

Downloaded from BUSINESS INSIDER JAPAN,
https://www.businessinsider.jp/post-186671, Mark Matousek, Mar.7 2019.

自動運転で居眠り？ ハイウェイを120キロで走行中のテスラのドライバー

Video

国家プロジェクト SIP-adus

Cross-Ministerial Strategic Innovation Promotion Program
Automated Driving for Universal Services (SIP-adus)

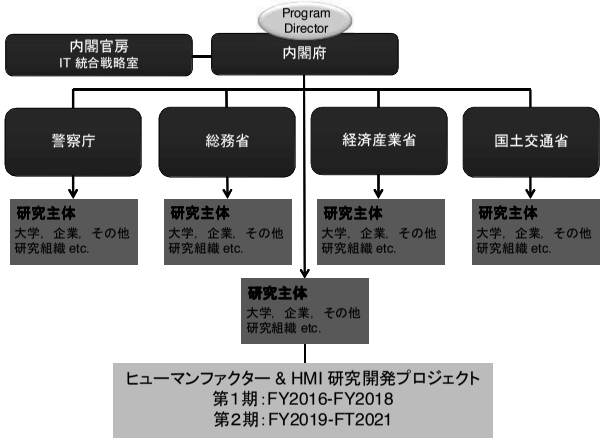

取り組み課題

自動走行システムと，ドライバー，周囲の交通参加者，および社会との3つのインタラクションにおけるヒューマンファクター課題を抽出．その中で協調領域に属し，かつ優先度の高い3つの課題を取り組み課題として設定

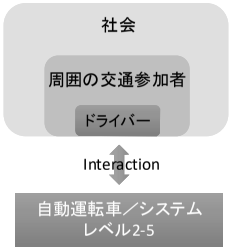

課題 A
Level 2, 3 自動走行システムの機能や状態に関する情報（知識情報&動的情報）が，運転引継ぎに及ぼす影響と，有効な情報伝達方法を明らかにする．

課題 B
Level 2, 3 自動走行中のドライバー状態（Readiness）が，運転引継ぎに及ぼす影響の理解と，ドライバーモニタリングのためのReadinessの指標化

課題 C
Level 2以上の自動走行車が備えるべき，他の交通参加者との路上コミュニケーション手段の設計指針の構築

研究開発体制

第１期産学連携コンソーシアム

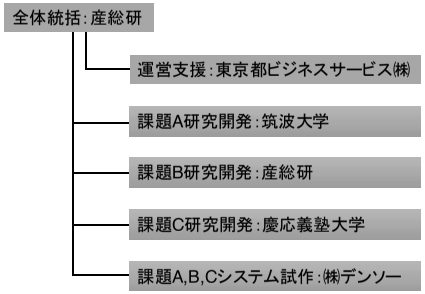

課題B目的

Level 2, 3 自動走行中のドライバー状態（Readiness）が，運転引継ぎに及ぼす影響の理解と，ドライバーモニタリングのためのReadinessの指標化

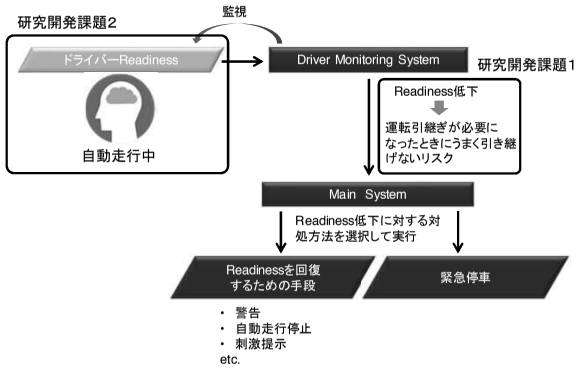

産総研 HCMRC

課題B実験方法

Phase 1: ドライビングシミュレータ実験

Phase 2: テストコース実験

ドライバーの生理・行動計測

Phase 1, 2で用いた実験シナリオ

Phase 3: 企業参加による実車公道実験(大規模実証実験)

産総研 HCMRC

課題B目的

Level 2, 3 自動走行中のドライバー状態(Readiness)が，運転引継ぎに及ぼす影響の理解と，ドライバーモニタリングのためのReadinessの指標化

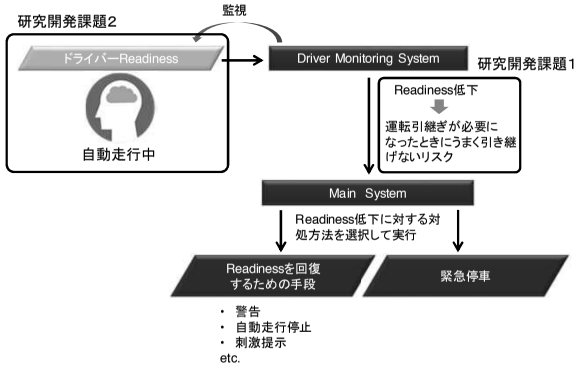

産総研 HCMRC

課題B結果

Level 2, 3 自動走行中のドライバー状態(Readiness)が，運転引継ぎに及ぼす影響の理解と，ドライバーモニタリングのためのReadinessの指標化

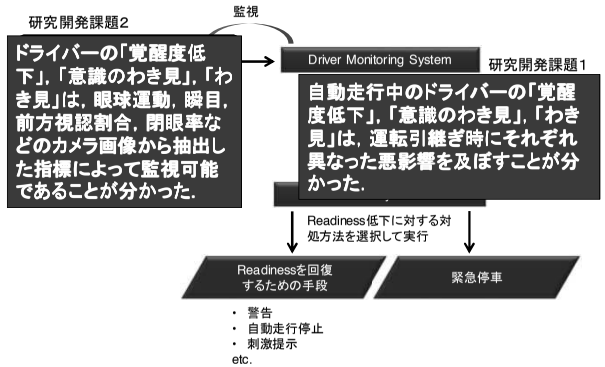

産総研 HCMRC

Key messages

- 今後複雑化するシステムに起因する新たなヒューマンファクター関連事故を起こさせないために，
  - 人の能力限界を正しく理解すること(人の変化や属性を考慮することが必要)
  - それをベースにシステムの機能／性能要求値を明確にすること
  - 人の能力を最大限引き出すことを支援する技術(HMIなど)の開発
  - 車載技術だけでなく教育や訓練についても考えてゆくこと

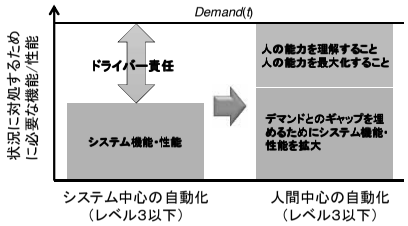

自動運転における前後方向制御のためのエネルギー最適制御の適用

○内田 博志（福山大学）

Application of Energy Optimal Control for Longitudinal Control in Autonomous Driving

* H. Uchida (Fukuyama University)

Abstract－ Energy optimal control (EOC) is applied to the case in that the hybrid electric vehicle performs position control. A virtual drive system driven by the position error signal is added to the model of the controlled object, and the power consumption is added to the evaluation function to derive the optimal control law. It is shown that good control is possible even when position control and energy allocation cannot be coordinated well with ordinary control.

Index terms－ autonomous driving, self-driving, optimal control, energy conservation

1　緒　言

ハイブリッド電気自動車（HEV）のエネルギー効率向上を目的とする最適制御の適用を考えたとき，次のような問題がある．1)評価関数を 2 次とする通常の最適制御では，消費エネルギーを最小化すると同時に回生エネルギー（負の消費エネルギーに相当する）を最大化するという制御目的を達成できない，2)ラグランジュ乗数の微分方程式を実時間で解きながら実行する非線形制御を行わなければならないが，エンジンとモーターの効率関数が非線形であるため，車載コントローラに搭載された安価なコンピュータでこれを実現することは，きわめて困難である．

以上の背景から，著者らは，本報告の第 2 著者が提案するエネルギー最適制御理論(EOC)[1)-3)]を，HEV のエネルギーフロー制御に適用している．過去の研究では，速度指令値に追従しつつ，最もエネルギー効率よく走行するＨＥＶのエネルギー最適制御を考えた[4) 5)]．しかし今後の車両のインテリジェント化，自動運転化を考えると，前車追従，自動走行などの位置制御の場合も考える必要があり，その場合には，過去の研究とは異なる考えが必要になる．

そこで本稿では，より位置制御に適した最適制御則導出法として，制御対象のモデルにおいて位置誤差の信号で駆動される仮想駆動システムを追加しこの消費パワーを評価関数に加え，最適制御則を導出する方法を試みる．

2　位置制御則の導出

図 1 に示す，位置決め動作を行う回転系を考える．アクチュエータは，目標角度 $\hat{\theta}$ を実現するためにトルク τ を発生するが，外乱力 f が存在するために，現実には誤差を持つ角度 θ が現れる．そこで f と釣り合う反対向きの仮想駆動力 $-f$ の分を含むようにトルク τ を決定すれば，誤差が解消されることになる．

この系のダイナミクスは次式で与えられる．

$$\tau = J\dot{\omega} + C\omega + Rf \tag{1}$$

この系の消費パワーを最小化する評価関数の被積分関数 L を次式で定義する．

$$L = \kappa P + rg \tag{2}$$

$$P = \left(J\dot{\omega} + C\omega + Rf - \tau\right)\omega \tag{3}$$

$$g = \phi\tau\omega \tag{4}$$

ここで P は系のパワー収支式，ϕ はアクチュエータの効率関数の逆数で，トルク τ と角速度 ω の関数である．κ，r は評価関数における P と g の重要度を配分する重み定数である．L にオイラー・ポアソンの方程式を適用すると，次式を得る．

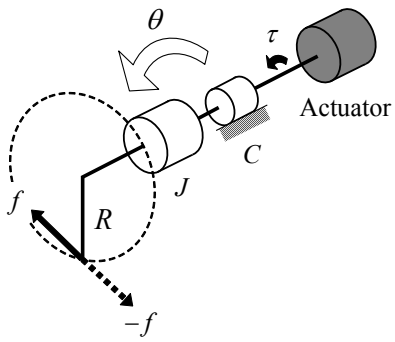

Fig.1 Rotating system

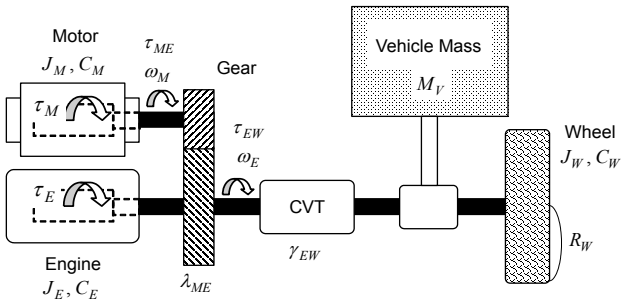

Fig.2 Schematic model of parallel HEV

$$\frac{\partial L}{\partial \omega}-\frac{d}{dt}\frac{\partial L}{\partial \dot{\omega}} =\left\{\kappa-r\left(\phi+\frac{\partial \phi}{\partial \omega}\omega\right)\right\}\tau-\kappa(2C\omega+Rf)=0 \tag{5}$$

これにより，アクチュエータの最適制御則は次式で与えられる．

$$\tau=\frac{2C\omega+Rf}{1-\dfrac{r}{\kappa}\left(\phi+\omega\dfrac{\partial \phi}{\partial \omega}\right)} \tag{6}$$

外乱 f は，自動車では転がり抵抗や空力抵抗などによって生じるものであるが，そのままの形で記述した制御則では，フィードバックによる誤差の収束がはかれない．そこでここでは $T_r=Rf$ のモデルの一例として，下記のＰＩＤ制御形のダイナミクスを用いる．ここで K_r , C_r はそれぞれ，位置制御に関するＰＩＤ制御の比例ゲインと微分ゲイン，J_r は加速度に関するフィードフォワードゲインである．

$$T_r=K_r\Delta\theta+C_r\Delta\omega+J_r\hat{\dot{\omega}} \tag{7}$$
$$\Delta\theta=\hat{\theta}-\theta,\quad \Delta\omega=\hat{\dot{\theta}}-\omega,\quad \hat{\dot{\omega}}=\hat{\ddot{\theta}}$$

すなわち式(6)による τ は，外乱 f を考慮しないエネルギー最適制御則に，外乱 f を打ち消すためのダイナミクスに基づく仮想駆動力 $-f$ の分を加えたものとなる．この式は位置に関するフィードバック制御の働きを持つため，過去の研究の考えとは異なり，式(2)の L に誤差低減のための項を意図的に加えずとも，良好に位置誤差が低減される制御則となる．この項はＰＩＤ制御形に限らず，どのような形のフィードバック則で与えても良い．

最初にこの式をモデル式の中に組み込まず f のままとしておいた理由は，θ などの変数が，オイラーポアソン方程式の適用による微分演算の対象となることを避けるためである．式(7)を微分演算の対象とすると，最適制御則がそのエネルギー収支を維持しようとする働きを持ち，期待される制御効果が得られない．

以上により，最終的に得られる制御則は次式となる．

$$\tau=\frac{2C\omega+T_r}{1-\dfrac{r}{\kappa}\left(\phi+\omega\dfrac{\partial \phi}{\partial \omega}\right)}=\frac{2C\omega+K_r\Delta\theta+C_r\Delta\omega+J_r\hat{\dot{\omega}}}{1-\dfrac{r}{\kappa}\left(\phi+\omega\dfrac{\partial \phi}{\partial \omega}\right)} \tag{8}$$

3　ＨＥＶのエネルギーフロー制御

3.1 ＨＥＶモデル

図２に示す，第２章と同様のパラレルＨＥＶを考える．ホイール，エンジン，モーターの角速度 ω_W , ω_E , ω_M の関係は，次式で与えられる．γ_{EW} はエンジンからホイールへの減速比の逆数，λ_{ME} はモーターからエンジンへの減速比である．

$$\omega_W=\gamma_{EW}\omega_E$$
$$\omega_M=\lambda_{ME}\omega_E$$

ホイール，エンジン，モーターの運動方程式は，それぞれ次式で与えられる．τ_{EW} はエンジンがホイールに与えるトルク，τ_{ME} はモーターがエンジンに与えるトルク，f_W は転がり抵抗や空力抵抗により発生するタイヤ接地面等価反力である．

$$\frac{\tau_{EW}}{\gamma_{EW}}=J_W\dot{\omega}_W+C_W\omega_W+R_Wf_W =J_W\gamma_{EW}\dot{\omega}_E+\left(C_W\gamma_{EW}+J_W\dot{\gamma}_{EW}\right)\omega_E+R_Wf_W \tag{9}$$

$$\tau_E+\lambda_{ME}\tau_{ME}-\tau'_{EW}=J_E\dot{\omega}_E+C_E\omega_E+T_E \tag{10}$$

$$\tau_M-\tau_{ME}=J_M\dot{\omega}_M+C_M\omega_M+T_M =J_M\lambda_{ME}\dot{\omega}_E+\left(C_M\lambda_{ME}+J_M\dot{\lambda}_{ME}\right)\omega_E+T_M \tag{11}$$

ここで τ'_{EW} は $f_W=0$ のときの τ_{EW} であり，T_E , T_M はそれぞれ，f_W に釣り合う仮想駆動力のエンジン分担分とモーター分担分である．

(9) (10) (11)より，$\dot{\omega}_E$ と τ_{ME} は，それぞれ以下の各式から得られる．

$$\dot{\omega}_E=\frac{\tau_E+\lambda_{ME}\tau_M-\gamma_{EW}R_Wf_W-\left\{C_E+\left(C_W\gamma_{EW}+J_W\dot{\gamma}_{EW}\right)\gamma_{EW}+\left(C_M\lambda_{ME}+J_M\dot{\lambda}_{ME}\right)\lambda_{ME}\right\}\omega_E}{J_E+J_W\gamma_{EW}{}^2+J_M\lambda_{ME}{}^2} \tag{12}$$

$$\tau_{ME}=\frac{\left(J_E+J_W\gamma_{EW}{}^2\right)\left(\tau_M-T_M-\left(C_M\lambda_{ME}+J_M\dot{\lambda}_{ME}\right)\omega_E\right\}-J_M\lambda_{ME}\left\{\tau_E-T_E-\left(C_E+C_W\gamma_{EW}{}^2+J_W\dot{\gamma}_{EW}\gamma_{EW}\right)\omega_E\right\}}{J_E+J_W\gamma_{EW}{}^2+J_M\lambda_{ME}{}^2} \tag{13}$$

τ'_{EW} を消去することにより，(10)は次式に書き換えられる．

$$\tau_E=\left(J_E+J_W\gamma_{EW}{}^2\right)\dot{\omega}_E+\left\{C_E+\left(C_W\gamma_{EW}+J_W\dot{\gamma}_{EW}\right)\gamma_{EW}\right\}\omega_E-\lambda_{ME}\tau_{ME}+T_E \tag{14}$$

3.2 制御則

以上のＨＥＶモデルに，第 2 節で述べた最適制御則導出法を適用する．(14) (11)より，エンジンとモーターのパワー収支 P_E , P_M は，それぞれ次式で表わされる．

$$P_E=\left\{\left(J_E+J_W\gamma_{EW}{}^2\right)\dot{\omega}_E+\left(C_E+C_W\gamma_{EW}{}^2+J_W\dot{\gamma}_{EW}\gamma_{EW}\right)\omega_E+\gamma_{EW}R_Wf_W-\tau_E-\lambda_{ME}\tau_{ME}+T_E\right\}\omega_E \tag{15}$$

$$P_M = \{J_M \dot{\omega}_M + C_M \omega_M - \tau_M + \tau_{ME} + T_M\}\omega_M \tag{16}$$

目的関数の被積分関数Lを，以下のように定義する．q_E，q_Mは，それぞれエンジンの燃料消費量とモーターの電力消費量，ϕ_E，ϕ_Mは，それぞれエンジンとモーターの効率関数の逆数，κ_E，κ_M，r_E，r_Mは重み定数である．

$$L = \kappa_E P_E + \kappa_M P_M + r_E q_E + r_M q_M \tag{17}$$

$$q_E = \phi_E \tau_E \omega_E \tag{18}$$

$$q_M = \phi_M \tau_M \omega_M \tag{19}$$

(17)に，ω_E，ω_Mに関するオイラーポアソン方程式を適用すると，

$$\begin{aligned}&\frac{\partial L}{\partial \omega_E} - \frac{d}{dt}\frac{\partial L}{\partial \dot{\omega}_E}\\ &= \left\{\kappa_E - r_E\left(\phi_E + \frac{\partial \phi_E}{\partial \omega_E}\omega_E\right)\right\}\tau_E\\ &\quad - \kappa_E\left[2\{C_E + (C_W\gamma_{EW} + J_W\dot{\gamma}_{EW})\gamma_{EW}\}\omega_E + \gamma_{EW}R_W f_W - \lambda_{ME}\tau_{ME} + T_E\right]\\ &= 0\end{aligned} \tag{20}$$

$$\begin{aligned}&\frac{\partial L}{\partial \omega_M} - \frac{d}{dt}\frac{\partial L}{\partial \dot{\omega}_M}\\ &= \left\{\kappa_M - r_M\left(\phi_M + \frac{\partial \phi_M}{\partial \omega_M}\omega_M\right)\right\}\tau_M - \kappa_M(2C_M\omega_M + \tau_{ME} + T_M)\\ &= 0\end{aligned} \tag{21}$$

(20)(21)より，エンジンとモーターの最適制御則はそれぞれ次式で与えられる．

$$\tau_E = \frac{2\{C_E + (C_W\gamma_{EW} + J_W\dot{\gamma}_{EW})\gamma_{EW}\}\omega_E - \lambda_{ME}\tau_{ME} + T_E}{1 - \dfrac{r_E}{\kappa_E}\left(\phi_E + \dfrac{\partial \phi_E}{\partial \omega_E}\omega_E\right)} \tag{22}$$

$$\tau_M = \frac{2C_M\omega_M + \tau_{ME} + T_M}{1 - \dfrac{r_M}{\kappa_M}\left(\phi_M + \dfrac{\partial \phi_M}{\partial \omega_M}\omega_M\right)} \tag{23}$$

タイヤ接地面反力f_Wに釣り合う仮想反力は，下記の位置誤差に関するＰＩＤ制御の形で与える．

$$T_E = K_{rE}\Delta\theta_E + C_{rE}\Delta\omega_E + J_{rE}\hat{\dot{\omega}}_E \tag{24}$$

$$T_M = K_{rM}\Delta\theta_M + C_{rM}\Delta\omega_M + J_{rM}\hat{\dot{\omega}}_M \tag{25}$$

$$\Delta\theta_W = \frac{1}{R_W}(\hat{x} - x) \tag{26}$$

$$\Delta\theta_E = \frac{\Delta\theta_W}{\gamma_{EW}} + \int \frac{\dot{\gamma}_{EW}\Delta\theta_W}{{\gamma_{EW}}^2}dt \tag{27}$$

$$\Delta\theta_M = \lambda_{EM}\Delta\theta_E - \int \dot{\lambda}_{EM}\Delta\theta_E dt \tag{28}$$

係数K_{rE}，K_{rM}，C_{rE}，C_{rM}は，第３章において考えた仮想回転系の減衰C_rと同様に，位置誤差や速度誤差によって変化し，それによってよりエネルギー効率に優れる運転が生じることを期待して，$\Delta\theta$と$\Delta\omega$に依存した非線形係数とする．ただし第３章において，仮想減衰はほぼ$\Delta\omega$のみに依存する結果が得られたので，C_{rE}，C_{rM}は$\Delta\omega$のみに依存する形とする．以下，K_{rE}，C_{rE}について式を示すが，K_{rM}，C_{rM}についても同様である．

$$C_{rE} = c_{rE0} + c_{rE1}|\Delta\omega_E| \tag{29}$$

$$c_{rE1} = \begin{cases} c_{rE1p} & (\Delta\omega_E \geq 0) \\ c_{rE1m} & (\Delta\omega_E < 0) \end{cases}$$

$$K_{rE} = k_{rE0} + k_{rE1}|\Delta\theta_E| + k_{rE2}|\Delta\omega_E| \tag{30}$$

$$k_{rE1} = \begin{cases} k_{rE1p} & (\Delta\dot{\omega}_E \geq 0) \\ k_{rE1m} & (\Delta\dot{\omega}_E < 0) \end{cases}$$

$$k_{rE2} = \begin{cases} k_{rE2p} & (\Delta\omega_E \geq 0) \\ k_{rE2m} & (\Delta\omega_E < 0) \end{cases}$$

4　シミュレーション

4.1 シミュレーション方法

車両に位置の目標値が直接与えられるのは，自動運転による場合が多いと考えられるため，シミュレーションにはドライバーモデルは含めず，位置（走行距離）の目標値に車両が直接追従する形のシミュレーションを行った．

制御対象車両にはたらく外乱は，空力抵抗f_Aところがり抵抗f_Rの和で与えた．

$$f_A = C_d A_f v^2 \tag{31}$$

$$f_R = F_R M_V \tag{32}$$

ＥＯＣとの比較例として，下記の式で求めたT_Wを，第２章で述べたルールベースト制御（ＲＢＣ）のアルゴリズムで，エンジンとモーターに振り分ける制御則を用いた．

$$T_E = K_{rE}\Delta\theta_E + C_{rE}\Delta\omega_E + J_{rE}\hat{\dot{\omega}}_E \tag{33}$$

K_{rW}，C_{rW}は，K_{rE}，C_{rE}などと同様の非線形係数とした．

4.2 前車追従シミュレーション

10 モード燃費計測の速度パターンにしたがって走行する前車に，一定距離で追従走行する制御シミュレーションを行った．言いかえれば，10 モード速度パターンの時間積分を位置目標とするシミュレーションを行った．ＥＯＣ，ＲＢＣいずれにおいても，走行終了

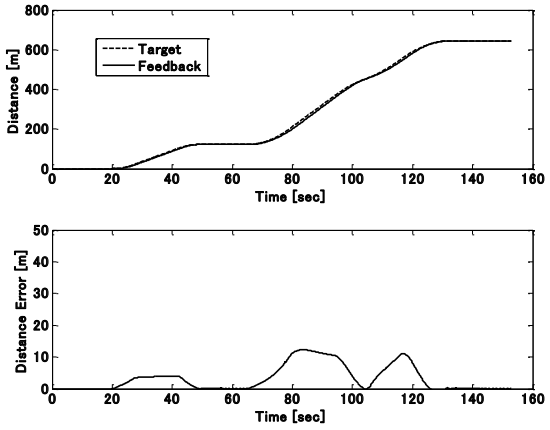

(a) EOC (upper: distance, lower: distance error)

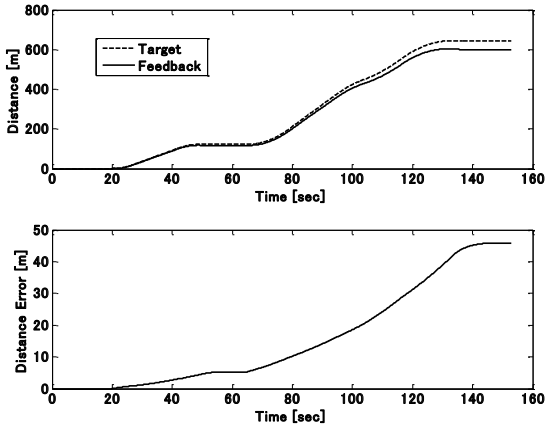

(b) RBC (upper: distance, lower: distance error)

Fig.3 Simulation results (tracking)

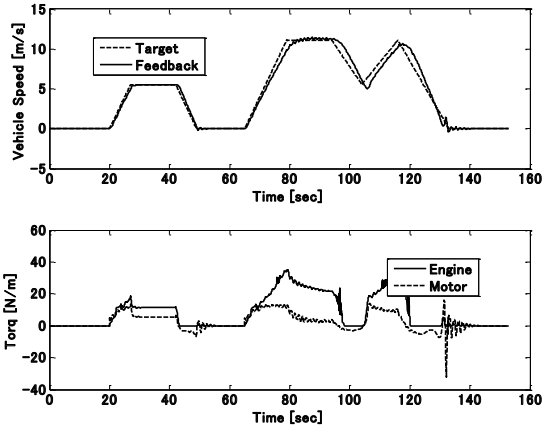

(a) EOC (upper: vehicle speed, lower: torque)

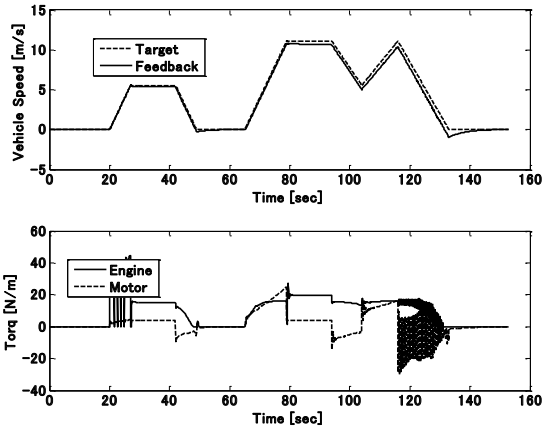

(b) RBC (upper: vehicle speed, lower: torque)

Fig.4 Simulation results (tracking)

時のモーターの消費エネルギーが 2×10^5［J］となるように制御を調整することにより，エネルギー性能を，エンジンのエネルギー消費量だけで比較できるようにした．

図 3 から図 5 にシミュレーション結果を示す．図 3 は移動距離と距離の誤差，図 4 は車両速度とトルク，図 5 はエネルギー消費量とエネルギー効率に関するシミュレーション結果である．いずれの図においても，(a)はＥＯＣの，(b)はＲＢＣのシミュレーション結果である．

図 3 に見るように，ＥＯＣでは目標値に対する位置誤差は最大 15m 程度に収まったが，ＲＢＣでは走行開始直後から追従の遅れが蓄積し続け，最終的には 50m 近い大きな位置誤差が発生して，良好な位置制御ができなかった．消費エネルギーに制約の加わる条件下での位置制御は，速度制御に比べてより困難なものであり，ＲＢＣでは良好な制御結果が得られなかったと考えられる．ＥＯＣはこのような場合でも，比較的良好な制御性能を発揮できている．

次に図 4 を見ると，ＥＯＣはＲＢＣに比べて挙動が滑らかであり，エンジンとモーターの間のパワーの配分が細かく行えている様子がうかがえる．またＲＢＣでは制御則の切り替えに伴う不安定傾向の挙動が発生しており，特に走行開始直後にエンジントルクが，また走行終了直前にモータートルクが大きな振動を伴っているが，ＥＯＣでは走行停止時にモータートルクに振動が発生しているほかは，大きな振動は発生していない．これらの結果として，ＥＯＣのエンジンエネルギー消費量はＲＢＣの 85.7%で済んだ．

4.3 目標位置停止シミュレーション

将来の車両制御では，目標地点を与えて，途中の走行パターンは車両に自動発生させる機能にもニーズが生じると考えられる．そのような場合を想定して，停止位置から 150m 離れた位置に 12 秒以内に移動して停止するシミュレーションを行った．初速と終速をゼロとする以外は，途中の位置や速度のパターンは与えなかった．ただし，最高速度は 20m/s を超えないこととした．またＥＯＣ，ＲＢＣいずれにおいても，走行終

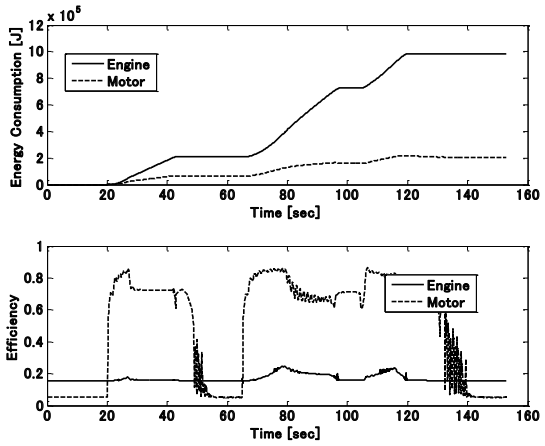

(a) EOC (upper: energy consumption, lower: efficiency)

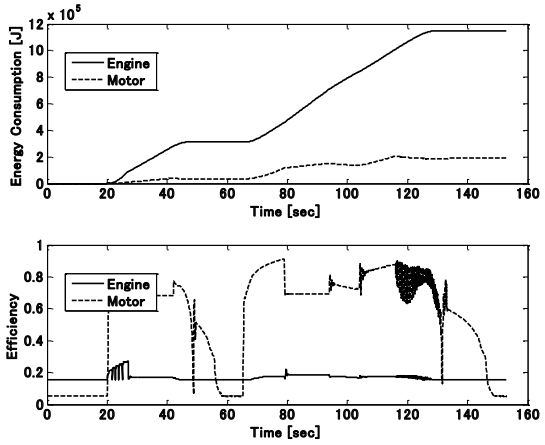

(b) RBC (upper: energy consumption, lower: effciency)

Fig.5 Simulation results (tracking)

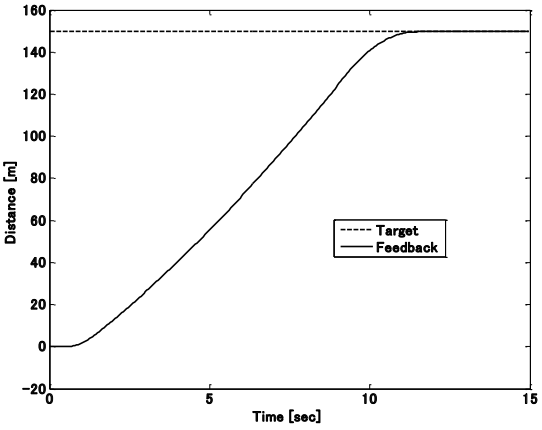

(a) EOC (distance)

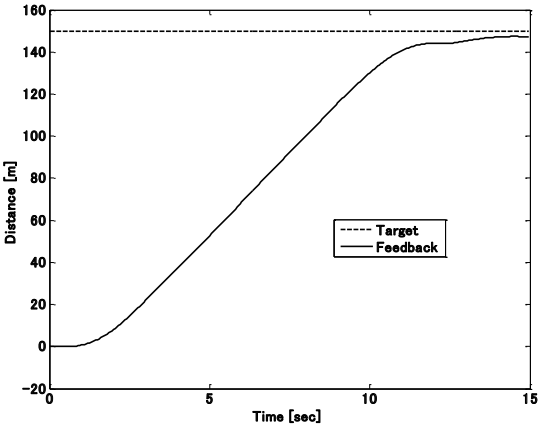

(b) RBC (distance)

Fig.6 Simulation results (start and stop)

了時にモーターの消費エネルギーがゼロとなるように制御を調整することにより，エネルギー性能を，エンジンのエネルギー消費量だけで比較できるようにした．

図 6 から図 8 にシミュレーション結果を示す．図 6 は移動距離，図 7 は移動速度とトルク，図 8 はエネルギー消費量とエネルギー効率に関するシミュレーション結果である．いずれの図においても，(a)はＥＯＣの，(b)はＲＢＣのシミュレーション結果である．

図 6，図 7 を見ると，ＲＢＣはシミュレーション終了段階において１５０ｍの目標地点に完全に到達しておらず，シミュレーション開始後から 12 秒経過後も速度とトルクは収束していない．また走行中のトルクは一部振動的な挙動を含んでおり，安定性も不足している．これに対してＥＯＣは 12 秒経過後に１５０ｍ先の目標地点に到達し，速度とトルクはほぼ完全に収束している．走行中の各曲線は滑らかで，安定した走行が行われたことが示されている．

図 8 に示すエネルギー効率の履歴を見ると，全体にＲＢＣの方が高効率な運転を実現しているが，最終的なエンジン消費エネルギー量は，ＥＯＣはＲＢＣの 92.3%で済んだ．この結果は，高効率な運転をすれば必ずしもエネルギー消費量が少なく済むわけではないことを示している．

ＥＯＣにおいてエネルギー消費が少ない理由として，制御則における効率関数の働きがある．第 2 章でも説明したように，式(22)(23)の制御則の分母の働きにより，ＥＯＣは，要求パワーが小さくエネルギー効率の低い動作領域では，なるべく動きを小さくとどめてエネルギー消費を抑えるが，いったん大きなパワーが必要になると，速やかに効率の高い動作領域に移動してなるべくエネルギー効率の高い運転を行おうとする働きを持つ．上記のシミュレーション結果は，大きなパワーを必要としないときには，むしろ低効率でもエネルギー消費が少ない動作領域で運転したほうが，エネルギー的には有利であるという，ＥＯＣの制御則が妥当なものであることを示しているといえる．

5　結　論

ハイブリッド電気自動車が位置制御を行う際の，エ

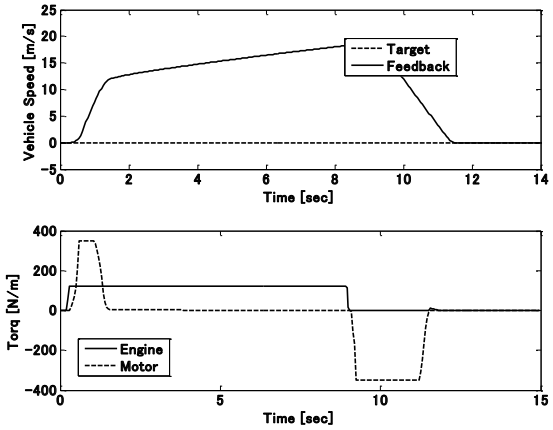

(a) EOC (upper: vehicle speed, lower: torque)

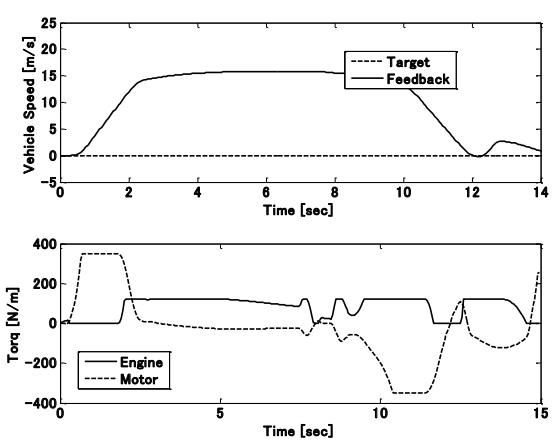

(b) RBC (upper: vehicle speed, lower: torque)

Fig.7 Simulation results (start and stop)

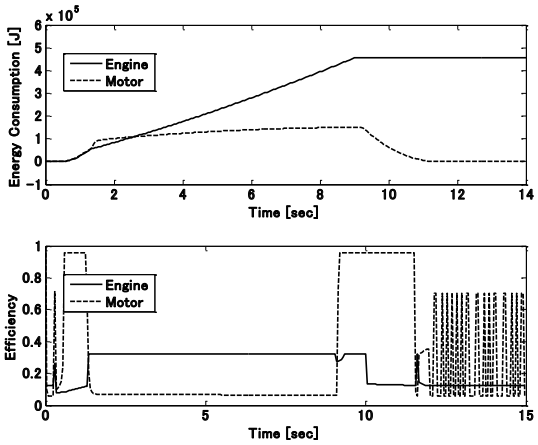

(a) EOC (upper: energy consumption, lower: efficiency)

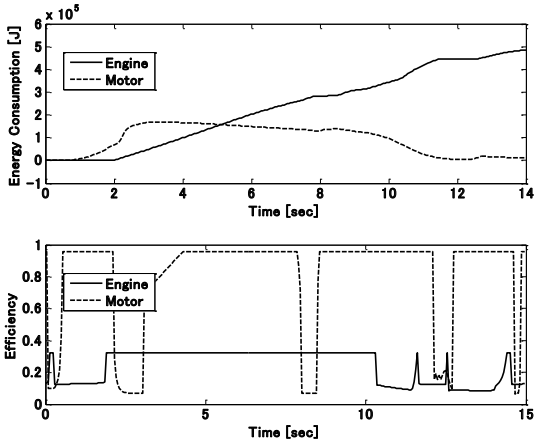

(b) RBC (upper: energy consumption, lower: efficiency)

Fig.8 Simulation results (start and stop)

ネルギー最適制御（ＥＯＣ）の適用法を考案した．位置制御に適した最適制御則導出法として，制御対象のモデルにおいて位置誤差の信号で駆動される仮想駆動システムを追加し，その消費パワーを評価関数に加え，最適制御則を導出する方法を試みた．

前車追従のシミュレーションでは，比較のルールベースト制御（ＲＢＣ）では良好な追従性が得られなかったが，ＥＯＣでは良好な追従結果が得られた．通常の制御では位置制御とエネルギー配分の強調がうまくはかれない場合でも，エネルギー最適制御によれば良好な制御が可能であることが示された．ＥＯＣのエンジンエネルギー消費量はＲＢＣの 85. 7%で済んだ．

また目標位置停止のシミュレーションでは，ＥＯＣではエンジンとモーターの効率関数の働きにより，エネルギー消費が効果的に抑制されたのに対し，ＲＢＣでは全体的に高効率な動作領域での運転が選択されたために，かえってエネルギー消費が増大した．これにより，ＥＯＣはＲＢＣの約 92%のエンジンエネルギー消費で済んだ．

ＥＯＣは，速度追従や位置追従などの通常の制御だけでなく，消費エネルギーを最小化する運動パターンや走行軌道の自動生成にも応用が可能であり，自動車分野における今後の幅広い展開が期待される．

文　献

1) 福島直人，太田翔，アルスラン セルチュク，萩原一郎 : エネルギー最適制御理論 －制御問題の新しい構成とそれに基づく最適制御理論－，日本機械学会第 11 回運動と振動の制御シンポジウム講演論文集, No.09-30, (2009), 109-113
2) 福島直人，萩原一郎：エネルギ収支に着目した新しい最適制御の構築とその適用，応用数理 Vol.17, No.2, (2007), 42-58
3) 福島直人：制御対象のエネルギー収支に着目した機械力学系の最適制御，日本機械学会論文集（C 編），Vol.72，No.722，(2006), 3106-3114
4) 内田博志, 福島直人, 萩原一郎 : エネルギー最適制御理論に基づくハイブリッド電気自動車のエネル

ギーフロー制御 －エンジンとモーターの最適トルク配分－，自動車技術会論文集, Vol.41, No.2, (2010), 461-468
5) 内田博志, 福島直人, 萩原一郎 : エネルギー最適制御理論に基づくハイブリッド電気自動車のエネルギーフロー制御 （第 2 報）－エンジン・モーター間にＣＶＴがある場合－，自動車技術会論文集, Vol.41, No.5, (2010), 1127-1132

自動運転における前後方向制御のためのエネルギー最適制御の適用

APPLICATION OF ENERGY OPTIMAL CONTROL FOR LONGITUDINAL CONTROL IN AUTONOMOUS DRIVING

内田 博志 Hiroshi Uchida
福山大学 Fukuyama University

第11回横幹連合コンファレンス
2020.10.8-9 統計数理研究所

1

はじめに

- 自動車の自動運転に対しては、主目的である運転負担の軽減や運転の安全性の向上に加えて、燃費性能の向上や、操縦安定性・乗心地性能の改善など、自動運転ならではの多様なメリットが期待できる。
- こうした場合の自動運転では、目標軌道や目標速度パターンに対する制御精度を維持しつつ消費エネルギーを最小化するなどの、多目的制御の実現が課題となる。
- 本研究では、ハイブリッド電気自動車（HEV）において、目標速度パターンに追従しつつ消費エネルギーを最小化する自動運転を行う場合について考える。

2

エネルギー最適制御

3

背景

- HEVのエネルギー効率向上を目的とする最適制御の適用を考えたとき，次の問題がある．
  1. 評価関数を2次形式とする通常の最適制御では，消費エネルギーを最小化し、同時に回生エネルギー（負の消費エネルギーに相当する）を最大化するという制御目的を達成するための解析解が得にくい
  2. 他方、ラグランジュ乗数の微分方程式を実時間で解きながら実行する非線形制御を行う場合には，エンジンとモーターの効率関数が非線形のため，車載用の安価なコンピュータでこれを実現することは困難である．

4

エネルギー最適制御

- 下記の評価関数 J を最小化する理想的なシステムの運動方程式を求める.

$$J = \int_{t_0}^{t} L d\tau \qquad (2)$$

ここで

$$L = \kappa P(q,\dot{q},\ddot{q}) + g(q,\dot{q},\ddot{q}) + ru^T\dot{q} \qquad (3)$$

$$P(q,\dot{q},\ddot{q}) = \ddot{q}^{\mathrm{T}} M(q)\dot{q} + d^{\mathrm{T}}(q,\dot{q})\dot{q} + e^{\mathrm{T}}(q,z)\dot{q} - v^{\mathrm{T}}\dot{q} \qquad (4)$$

5

エネルギー最適制御

- 制御入力 u が与えられれば，式(2)が最小化されるための制御対象の挙動の必要条件から，次のオイラー・ポアソン方程式が得られる.

$$\frac{\partial L}{\partial q} - \frac{d}{dt}\left(\frac{\partial L}{\partial \dot{q}}\right) + \frac{d^2}{dt^2}\left(\frac{\partial L}{\partial \ddot{q}}\right) = 0 \qquad (5)$$

- 式(5)を積分し，積分定数をゼロとすると，次式になる.

$$\int \frac{\partial L}{\partial q} dt - \frac{\partial L}{\partial \dot{q}} + \frac{d}{dt}\left(\frac{\partial L}{\partial \ddot{q}}\right) = 0 \qquad (6)$$

6

エネルギー最適制御

- 式(3)を式(6)に代入することにより，制御対象が振舞うべき理想システムの運動方程式が得られる. この理想特性を閉ループ系の制御則とすることにより，制御対象の入出力は，あたかも理想特性であるかのごとく振舞う.
- 理想特性は，オイラー・ポアソン方程式を用いて評価関数の被積分関数を変換することにより得られるため，微分方程式を解く必要はない.
- これは，閉ループを構成する現実の制御対象の運動とコンピュータ内の理想特性とが，協調して実時間で連立方程式を解く働きをすることによる.

7

エネルギー最適制御

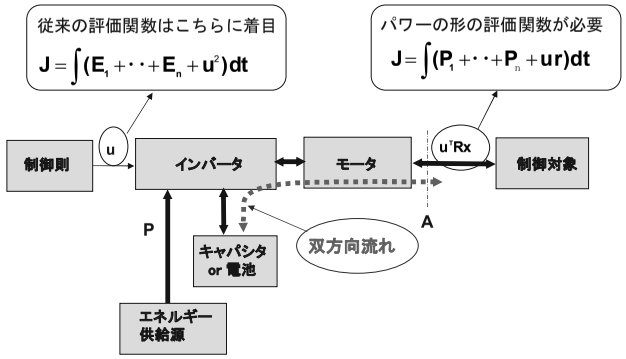

8

HEVのエネルギーフロー制御

9

HEVモデル

- 制御対象として，図のパラレルHEVモデルを考える．エンジンがCVT(無段変速機)を介してホイールを駆動し，モーターが一定減速比のギヤを介してエンジンに結合されている．

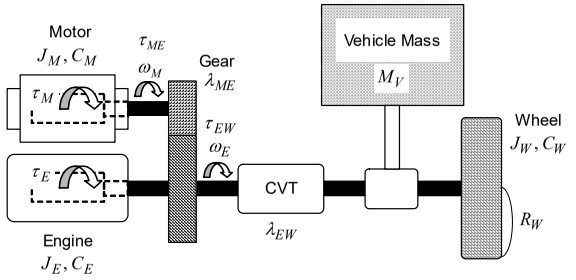

10

制御則

- エンジン、モーターの制御則は，以下のように導出される．

$$\tau_E = \frac{\kappa\left(2C_{ES} - \dot{J}_{ES}\right)\omega_E + r_1\left(\hat{\omega}_M - \omega_M\right) + r_2\left(\hat{\dot{\omega}}_M - \dot{\omega}_M\right) + r_3\dot{\omega}_M - \kappa\lambda_{ME}\tau_{ME}}{\kappa + r - \frac{r_4}{f_E}\left(1 - \frac{\omega_E}{f_E}\frac{\partial f_E}{\partial \omega_E}\right)} \quad (25)$$

$\therefore$

$$\tau_M = \frac{2\kappa C_M\omega_M + r_1\left(\hat{\omega}_E - \omega_E\right) + r_2\dot{\omega}_E + r_3\left(\hat{\dot{\omega}}_E - \dot{\omega}_E\right) + \kappa\tau_{ME}}{\kappa + r - \frac{r_5}{f_M}\left(1 - \frac{\omega_M}{f_M}\frac{\partial f_M}{\partial \omega_M}\right)} \quad (27)$$

11

シミュレーション

- エネルギー最適制御に基づくHEV制御(以後EOC)制御方策の妥当性を検証するため，国土交通省の定める10モード燃費測定の走行パターンを模擬するシミュレーションを行った．

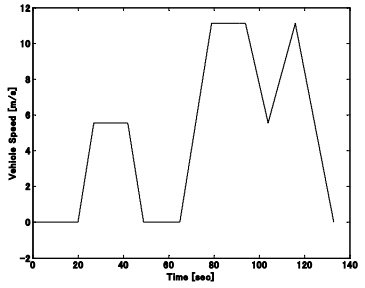

12

エネルギー消費量

EOC

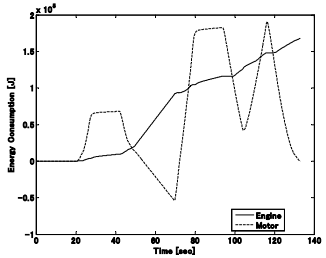

RBC

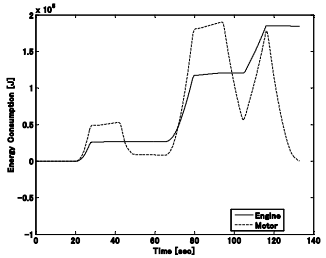

13

エンジンのエネルギー効率

EOC

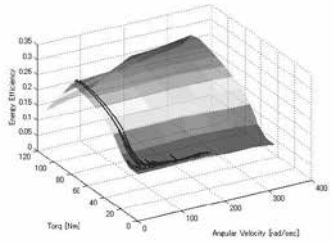

RBC

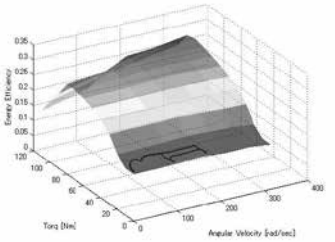

14

モーターのエネルギー効率

EOC

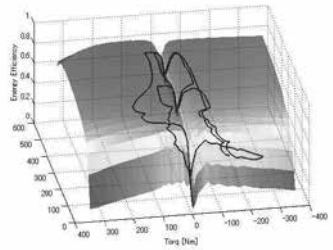

RBC

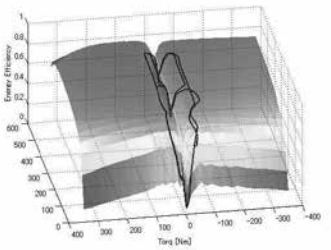

15

EOCによる位置制御

16

位置制御のためのエネルギー最適制御

- 今後のインテリジェント化された自動車は，安全性の向上や運転者の負担軽減のための自動走行機能，すなわち距離情報や位置情報に基づく前車追従や目標位置停止，速度パターンや走行軌道のリアルタイム生成に基づく自律走行などの機能を持つようになると考えられる．
- そのような位置制御を行う場合には，速度制御のための制御則に単純に位置誤差項を加えただけでは，位置制御とエネルギー抑制の良好な両立は得られない．
- そこで位置制御に適したEOC制御則導出法として，制御対象のモデルにおいて位置誤差の信号で駆動される仮想駆動システムを追加してその消費パワーを評価関数に加え，最適制御則を導出する方法を用いる．

17

17

仮想回転系

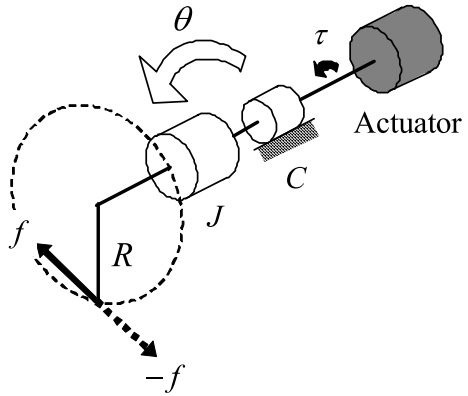

18

18

位置制御則の導出

- 前図に示す，位置決め動作を行う回転系を考える．アクチュエータは，目標角度 $\hat{\theta}$ を実現するためにトルク τ を発生するが，外乱力 f が存在するために，現実には誤差を持つ角度 θ が現れる．
- そこで f と釣り合う反対向きの仮想駆動力 $-f$ を含むようにトルク τ を決定すれば，誤差が解消されることになる．
- そこでここでは仮想駆動力のモデルの一例として，下記のPID制御形のダイナミクスを用いる．ここで K_r, C_r はそれぞれ位置制御に関するPID制御の比例ゲインと微分ゲイン，J_r は加速度に関するフィードフォワードゲインである．

$$T_r = K_r \Delta\theta + C_r \Delta\omega + J_r \hat{\dot{\omega}} \qquad (4.7)$$

19

パラレルHEVの概略モデル

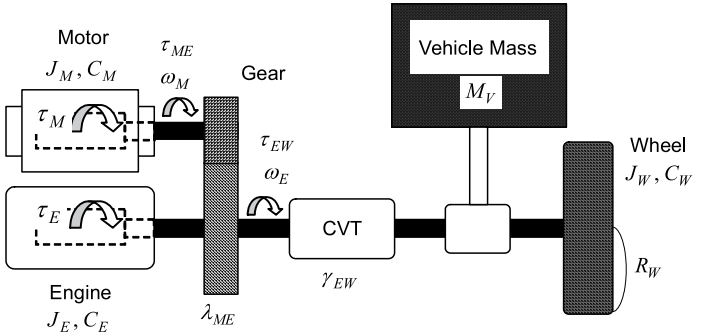

20

20

制御則

- エンジンとモーターの最適制御則はそれぞれ次式で与えられる.

$$\tau_E = \frac{2\{C_E + (C_W\gamma_{EW} + J_W\dot{\gamma}_{EW})\gamma_{EW}\}\omega_E - \lambda_{ME}\tau_{ME} + T_E}{1 - \frac{r_E}{\kappa_E}\left(\phi_E + \frac{\partial\phi_E}{\partial\omega_E}\omega_E\right)} \quad (22)$$

$$\tau_M = \frac{2C_M\omega_M + \tau_{ME} + T_M}{1 - \frac{r_M}{\kappa_M}\left(\phi_M + \frac{\partial\phi_M}{\partial\omega_M}\omega_M\right)} \quad (23)$$

21

21

前車追従シミュレーション

- 10モード燃費計測の速度パターンにしたがって走行する前車に，一定距離で追従走行する制御シミュレーションを行った．すなわち，10モード速度パターンの時間積分を位置目標とするシミュレーションを行った.
- EOC，RBCいずれにおいても，走行終了時のモーターの消費エネルギーが2×10^5 [J]となるように制御を調整することにより，エネルギー性能を，エンジンのエネルギー消費量だけで比較できるようにした.

22

22

前車追従シミュレーション

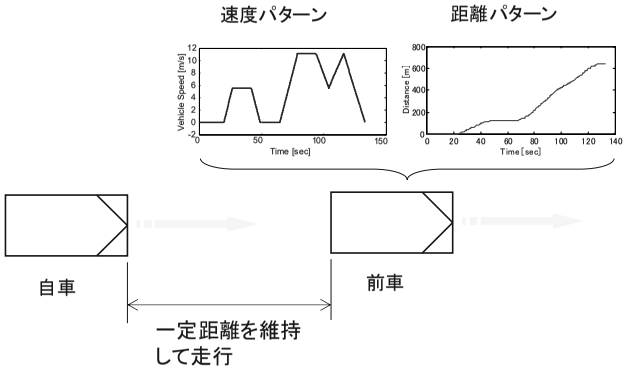

23

23

移動距離と距離の誤差（前車追従シミュレーション）

(a) EOC（上：移動距離　下：距離の誤差）

(b) RBC（上：移動距離　下：距離の誤差）

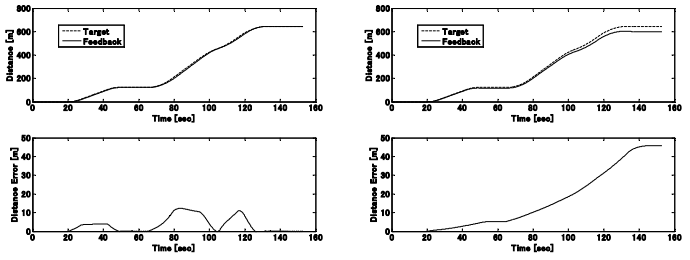

24

24

エネルギー消費量とエネルギー効率（前車追従シミュレーション）

(a)

(a) EOC（上：エネルギー消費量，下：効率）

(b) RBC（上：エネルギー消費量，下：効率）

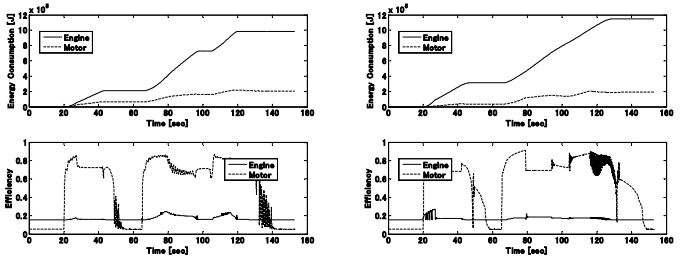

25

25

エンジンのエネルギー消費量（前車追従シミュレーション）

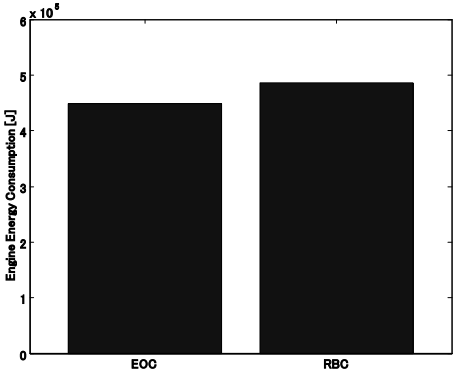

26

26

目標位置停止シミュレーション

- 将来の車両制御では，目標地点を与えて，途中の走行パターンは車両に自動発生させる機能にもニーズが生じると考えられる．
- そのような場合を想定して，停止位置から150m離れた位置に12秒以内に移動して停止するシミュレーションを行った．初速と終速をゼロとする以外は，途中の位置や速度のパターンは与えなかった．
- ただし，最高速度は20m/sを超えないこととした．またEOC，RBCいずれにおいても，走行終了時にモーターの消費エネルギーがゼロとなるように制御を調整することにより，エネルギー性能を，エンジンのエネルギー消費量だけで比較した．

27

27

目標位置停止シミュレーション

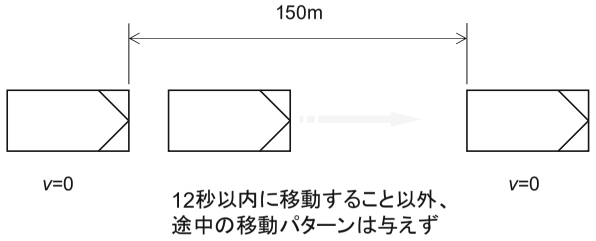

28

28

移動距離
（目標位置停止シミュレーション）

(a) EOC　　(b) RBC

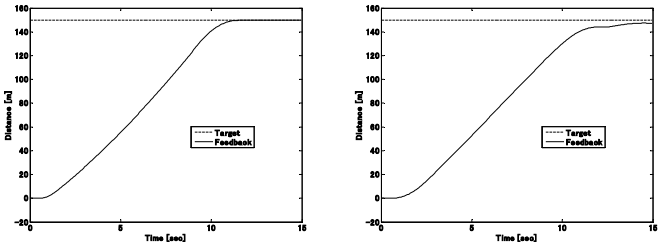

29

29

エネルギー消費量とエネルギー効率
（目標位置停止シミュレーション）

(a)

(a) EOC（上：エネルギー消費量，下：効率）　(b) RBC（上：エネルギー消費量，下：効率）

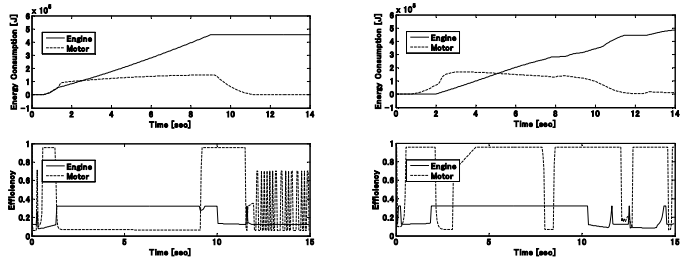

30

30

エンジンのエネルギー消費量
（目標位置停止シミュレーション）

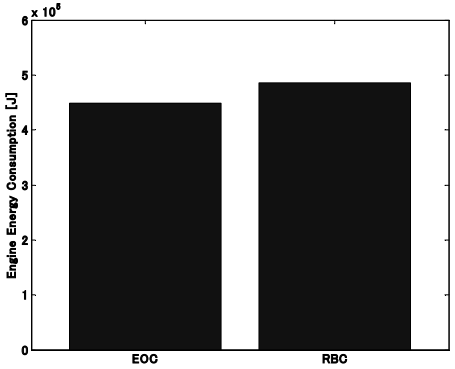

31

31

まとめ

- HEVが位置制御を行う際の，エネルギー最適制御(EOC)の適用法を考案した．制御対象のモデルに位置誤差の信号で駆動される仮想駆動システムを追加し，その消費パワーを評価関数に加え，最適制御則を導出する方法を試みた．
- 通常の制御では位置制御とエネルギー配分の強調がうまくはかれない場合でも，EOCによれば良好な制御が可能であることが示された．前車追従のシミュレーションでは，EOCのエンジンエネルギー消費量はRBCの86%，目標位置停止シミュレーションでは92%で済んだ．
- EOCは，消費エネルギーを最小化する運動パターンや走行軌道の自動生成にも応用が可能であり，自動車分野における今後の幅広い展開が期待される．

32

32

自動走行システムの安全性評価手法

○今関 隆志（東京農工大学）菅沢 深（東京農工大学）趙 開開（東京農工大学）
望月 悠登（シチズン時計）毛利 宏（東京農工大学）

Evaluation Methodology of Safer Autonomous Driving Vehicles

* T.Imaseki (Tokyo University of Agriculture and Technology), F.Sugasawa (Tokyo University of Agriculture and Technology), K.Zhao (Tokyo University of Agriculture and Technology),Y.Mochizuki (Citizen Watch), H.Mouri (Tokyo University of Agriculture and Technology)

Abstract－ Near-miss database consists of video data of real-world dangerous situations. It can be classified into the overt dangerous situation, which is obviously approaching accident, the potentially dangerous situation which has probability to get into the overt dangerous situation, and the normal driving situation. In order to assure safety driving of autonomous vehicle, it is necessary to evaluate whether the vehicle would be operated according to the scenarios which avoid not only the overt dangerous situations but also the potentially dangerous situations. In this paper, using technologies of object detection and measurement on the near-miss video data, and using theoretical concept of potential risk indicator, rear-end type near-miss data were analyzed, the potential risk indicators were calculated, and the potentially dangerous situations were defined. Then, a novel evaluation method of safer autonomous driving vehicles is proposed.

Index terms－ Autonomous driving, Safety, Accident avoidance, Collision prediction, Near-miss analysis

1　まえがき

複雑な交通環境でも自動車を安全に走行させることのできるドライバーの特徴は，（a）常に，潜在的に危険な状態を予測し，自ら危険を引き起こす又巻き込まれるような行為をしないことであり，（b）危険な状態が発生したら迅速な回避行動をとることである．したがって，安全運転ドライバーと同等以上に安全走行する自動走行システムは，上記（a）と（b）の機能実現が必須となり，自動走行システムを社会実装する際の安全性評価の目的は，起り得る交通環境の下で，これらの機能実現を評価・確認することである．このうち（b）については，緊急回避ブレーキシステム（AEB）などの衝突回避システムとその評価方法が検討対象としているため，本論文では特に（a）に焦点をあてた評価方法を検討する．具体的には，潜在的危険状態を定義し，走行状態の潜在的危険度を定量化する方法を明らかにする．さらに，実際のニアミスデータにおいて潜在的危険度を分析することにより，この潜在的危険度指標の妥当性検証を行う．こうした研究を通じ，自動走行システムの社会実装に必要な，安全性評価に関するシナリオ条件導出の考え方を明らかにしていく．

2　潜在的危険状態の定義

潜在的危険度指標を導入するにあたり，発生頻度の高い追突シナリオ(追突に至るシナリオ)を例にとり，「常に，潜在的に危険な状態を予測し，自ら危険を引き起こす又巻き込まれるような行為をしない」ということを，単純化したモデルで考察する．

Fig.1において，イニシャル状態では，自車（赤）は，先行する対象車（青）に対して短い相対距離で走行している．この後，もし対象車が突然制動した場合，両車両は，追突という危険な状態に突入する．したがって，このようなイニシャル状態こそが，衝突回避不可能な危険状態を引き起こす潜在的危険状態であったと考えられる．一方，Fig.2のように，イニシャル状態において両車の相対距離が大きい場合，もし対象車が突然制動しても，自車は余裕持った制動により追突を回避でき，危険な状態には陥らない．すわなち，このようなイニシャル状態は，潜在的危険状態ではなかったと考えられる．こうした考察をもとに，危険な状態を定性的に分類することができる．危険の顕在性／潜在性の分類軸と，危険からの回避性の分類軸のマトリックスで定義したのがTable.1である．先に述べたように，本稿では（a）に注目しているので，Table.1においてpotentially danger（潜在化危険）の行にのみ注目する．その中で，potentially critical unpreventableとは，その状態で，もし先行車が突然制動したら自車は回避不可能になることを表す．potentially critical preventableとは，その状態で，もし先行車が突然制動したら自車としては急制動して回避できるということを表す．potentially normalもしくはpotentially normal preventableとは，その状態で，もし先行車が突然制動しても自車としては通常運転の範囲であることを表す．この表から読み取ると，安全走行する自動走行システムは，potentially critical unpreventable状態には決して入ってはならず，また，potentially critical preventable状態にあったら，迅速にpotentially normal状態に戻る必要がある，と換言することができる．

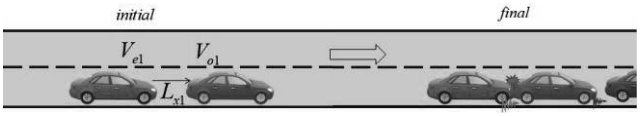

Fig. 1 Rear-end collision scenario with initial distance L_{x1}.

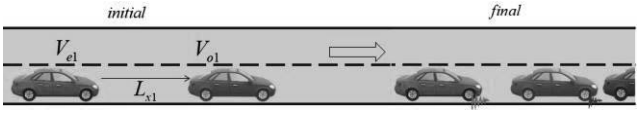

Fig. 2 Rear-end collision scenario with initial distance L_{x2}.

Table.1 Danger situation classification

Danger recognizable-ness	Danger preventability			
	by not emergency action		by emergency action	
	physically preventable			physically unpreventable
potentially danger	potentially-normal	potentially-normal preventable	potentially-critical preventable	potentially-critical unpreventable
overt danger	normal	normal preventable	critical preventable	critical unpreventable

3 分析方法

潜在危険度指標の概念を導入し，東京農工大ニアミスデータベース中の追突ニアミスデータにおける潜在危険指標を計算することによって，これらの潜在危険状態を定量的に明らかにしていく．

3.1 ニアミスデータベース

東京農工大では，日本の五地域で車両にドライブレコーダを装着し，交通ニアミスデータを蓄積してきた[1][2]．現在までに，一般道・自動車専用道を含む道路環境で，Video 画像と物理量形式で記録された追突ニアミスデータ（事故，ニアミス程度違いを含む）を蓄積している（Fig.3）．本稿では，ここから取り出したデータにおいて，自動車専用道走行における追突ニアミスデータの潜在危険状態の分析を行った．

Fig. 3 Rear-end collision data from Near-miss database.

3.2 ニアミスデータの計測

ニアミス Video 画像データから対象車の位置を計測するには，Video 画像から対象物を自動検出し，検出された対象物との相対距離を計測する必要がある．実際のニアミス Video 画像データ用に開発した，対象物自動検出・識別・トラッキング・相対位置測定のシステム（Fig.4）を活用し，ニアミスデータの計測を行った．

Fig. 4 Object detection and distance measurement system.

3.3 潜在危険指標の計算

先行して走行中の対象車への追突シナリオでは，単路同一車線を先行対象車と自車が一定の相対距離で走行している状態から，先行対象車が一定減速度 G_o で急減速すると仮定した場合の，自車が，先行対象車との衝突を回避するために最低限必要な減速度（DCA）を計算する．これは，単路同一車線を先行対象車と自車が一定の相対距離で走行している状態の潜在的危険性を定量的に計算していることに等しい．先行して走行中の対象車への追突シナリオにおける DCA の計算方法は[3][4]に従った．すなわち，自車と対象車の走行環境状態は，Fig.5 の左側のようなイニシャル状態にあったとする．自車の車速 V_{e1}，対象車の車速 V_{o1}，自車と対象車の相対距離（自車の先端から対象車の後端まで）を L_{x1} とする．この時刻以降，Fig.5 のように，対象車が減速度 G_o で急減速したと仮定し，これに衝突するのを回避するため，自車に必要な減速度 DCA を計算する．

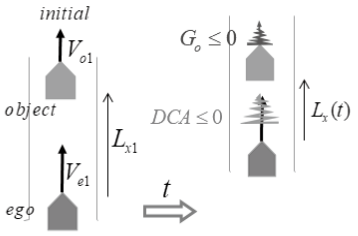

$$L_x(t)=\frac{1}{2}\cdot(G_o-DCA)\cdot t^2+[(V_{o1}-V_{e1})+DCA\cdot\tau]\cdot t+L_{x1}-\frac{1}{2}\cdot DCA\cdot\tau^2$$

V_{e1} : ego vehicle initial speed
V_{o1} : object vehicle initial speed
L_{x1} : initial relative distance between ego and object
G_{ox} : assumption of object vehicles' sudden deceleration
DCA : required acceleration of ego vehicles to prevend colliding against the object
τ: delay of DCA acceleration

Fig. 5 Rear-end collision DCA calculation concept.

4 分析方法

4.1 追突ニアミスデータの分析と危険状態の判定

自動車専用道路走行中の先行対象車の急減速により，自車が衝突した事例のデータで，上記の DCA 計算を行った結果を Fig.6 に示す. 赤の実線が DCA 値であり，各時刻 t の状態において，もし対象車が G_o=-0.7g で急減速した場合，自車はどれだけの減速度で減速すれば衝突を回避できるかを計算し，DCA 値として示した．t=-5.5s～-4s の間は，もし対象車が急減速しても，自車は DCA=-0.4g 程度で減速すれば衝突を回避できることになり，すなわち，potentially normal preventable 状態にあったとみなせる．t=-2.5s では，もし対象車が急減速した場合，自車は DCA=-0.6g で強く減速して衝突を回避できることになり，すなわち，potentially critical preventable 状態になったとみなせる．t=-1.2s 以降，もし対象車が急減速した場合，自車は衝突を回避するには DCA=-1g より強く減速しなければならないことになり，物理的に回避不可能，すなわち，potentially critical

unpreventable 状態に入ったとみなせる．このような潜在危険指標 DCA 値の変化があった後，このデータの結末は，追突事故に至っている．

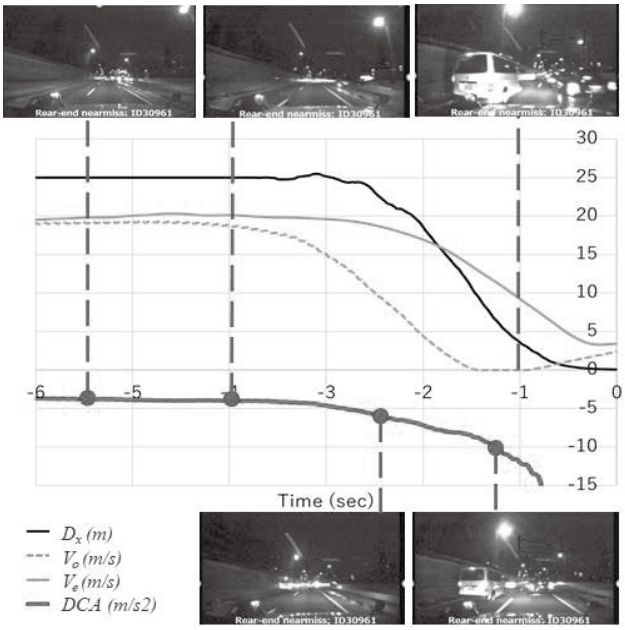

Fig. 6 DCA calculation result from Rear-end data.

このような分析結果から言えることは，自車の走行環境が potentially normal preventable 状態か potentially critical preventable 状態にある場合，その状態を維持するか，或いは制動を行い，potentially critical unpreventable 状態には入らないようにすべきであった，ということになる．したがって，先行して走行中の対象車への衝突シナリオで，自動走行システムの社会実装のための安全性評価を行う場合，（L_{x1}，V_e，V_o）で定まる走行状態で走行させ，そこから，決して potentially critical unpreventable 状態に入らないことを評価するべきである．これが，潜在的に危険な状態を常に予測し，自ら危険を引き起こす行為をしないことの実現になろう．

このような潜在危険指標の分析件数を増やし，実際の交通走行環境で起きうる状態を統計的に分析していく必要がある．これまでに集めた多数のニアミスデータを使い，（L_{x1}，V_e，V_o）空間上で，潜在危険度指標 DCA の軌跡の分布を求めた．Fig.7 では，（L_{x1}，V_e，V_o）空間上に，理論的に DCA が-0.3g に等しい曲面（黄），-0.6g に等しい曲面（赤），-1.0g に等しい曲面（黒）が描かれている．この図には，研究者のサブジェクティブ評価により Low レベルのニアミス（危険を感じたが，通常操作で衝突を回避した）と判定されたデータの分布が示されている．ニアミスレベル Low のデータの潜在危険度 DCA 軌跡の分布は，潜在危険度 DCA＝-0.3g 付近に集中する（すなわち，potentially normal～potentially normal preventable 状態にある）傾向を示している．また，Fig.8 のように，サブジェクティブ評価でのニアミスレベル High のデータ（大きな危険を感じ，緊急回避操作で衝突を回避できた）の潜在危険度 DCA 軌跡は，潜在危険度 DCA＝-0.6g 以上に入る（すなわち，potentially critical preventable 状態に入る）傾向を示している．そして，Fig.9 のように，実際に事故に至ったデータの潜在危険度 DCA 軌跡の分布は，潜在危険度 DCA＝-1.0g 以上に突入する（すなわち，potentially critical unpreventable 状態に入る）傾向を示している．以上のように，本稿で提案した潜在危険度の分析モデルは，実際のニアミスデータにおいても，その危険性を定量表現するのに妥当なものだと考えられる．

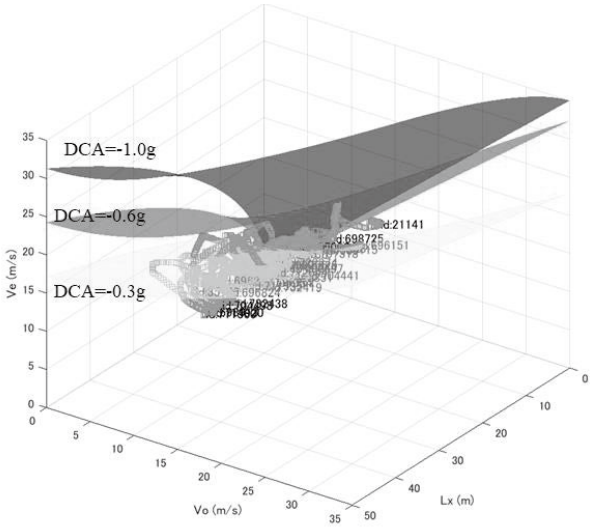

Fig. 7 Trajectories of low level near-miss rear-end data.

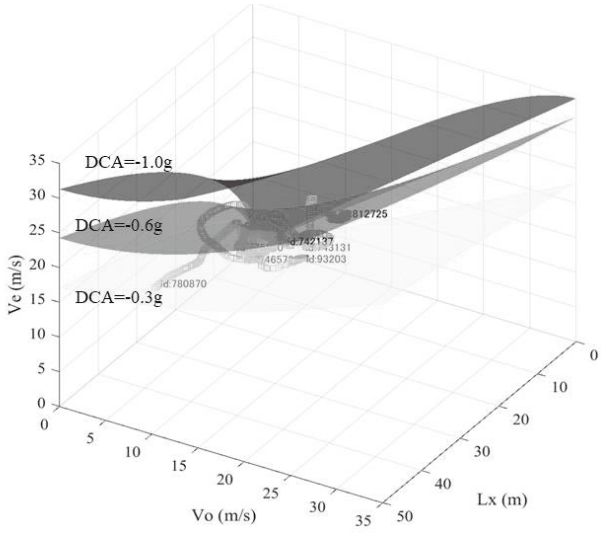

Fig. 8 Trajectories of high level near-miss rear-end data.

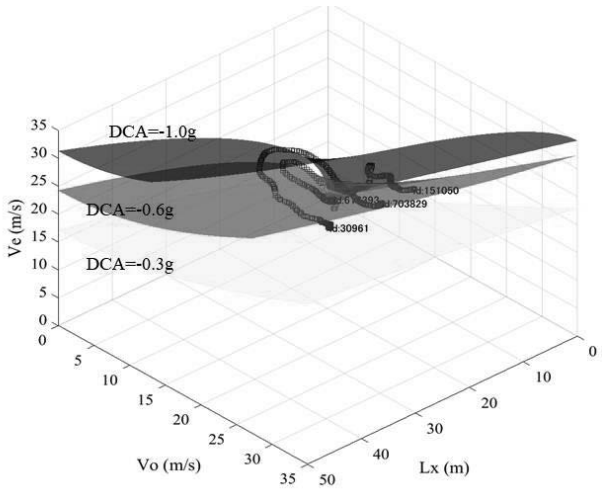

Fig. 9 Trajectories of rear-end accidents data.

5　まとめ

自動走行システムを社会実装するための安全性評価方法を検討するにあたり，まず，走行環境の危険状態を，顕在性／潜在性という切り口と，危険からの回避性という切り口から，危険状態を分類し，定義した．単路直進走行中の自動走行システムが安全走行を継続するためには，もしその状態から先行車の動きが変化したら既に回避不能になる状態が潜在危険 Potentially critical unpreventable 状態だとし，この状態に入らぬように走行しなければならないことを明らかにした．
単路同一車線を先行対象車と自車が一定の相対距離で走行しているシナリオを考えた場合，この状態は，自車速度 V_e，対象車の速度 V_o，自車と対象車の相対距離 L_{x1} のパラメータで決まることを明らかにし，このパラメータから計算される潜在危険度の大きさ指標 DCA の計算方法も明らかにした．さらに，この計算を，実際のニアミスデータにあてはめ，潜在危険度の定義の妥当性を検証した．

これらの結果として，先行走行中の対象車への追突シナリオにおいて，自動走行システム安全性評価に関するシナリオ条件導出の考え方が明らかになった．今後，自動車走行中に遭遇する追突以外のシナリオについても検討していくことにより，自動走行システムの安全性評価方法が構築される．

謝辞

本研究は，経済産業省および日本自動車研究所の SAKURA プロジェクトイニシャティブの支援を受けたものであり，感謝の意を表します．

参考文献

1) M. Fujita: Analysis of Low-speed Rear-end Collisions using Near-miss Incident Database, Fast-Zero symposium Proceedings (2011).
2) Y. Akagi: Ontology based collection and analysis of traffic event data for developing intelligent vehicles, IEEE 6th Global Conference (2017).
3) T. Hiraoka. S. Takada: Collision Risk Evaluation Based on Deceleration for Collision Avoidance, Transactions of the Society of Instrument and Control Engineers, vol.47-11 pp.534-540 (2011).
4) 菅沢 深 他:ドライブレコーダに記録されたニアミスデータを用いた危険走行シナリオの研究 2-ニアミス事象を定量化する潜在危険度の理論研究，自動車技術会学術講演会予稿集(2020).

自動走行システムの安全性評価手法

Evaluation Methodology of Safer Autonomous Driving Vehicles

第11回横幹連合コンファレンス

2020.10.9
東京農工大学
今関　隆志

研究の背景

- 人間によって運転される自動車は，道路交通環境における様々な交通障害を回避し，事故に陥らないよう，常に人間が操作して運転されている．
- 自動走行システムレベル3（自動車専用道等において，一定の条件下ではシステムが運転責任をもつ）以上の自動運転システムが技術的に開発され，順次導入されようとしている．
- このような自動走行システムが，実際の道路環境で人間ドライバーの行なっている運転以上の安全運転が出来るかどうか？社会実装の前に評価しなければならない．
- このような自動走行システムの走行安全性評価として，社会で起こり得るすべての交通環境条件（数十億キロ走行中に遭遇するすべての交通環境）において，ひとつひとつ実験をすることは不可能であり，コンピュータシミュレーションでのみ可能性がある．

自動走行システムの安全性評価方法を研究する

コンピュータによる自動車走行シミュレーションにおいて，

I.　実際に起き得る複雑多様な走行環境を仮想設定できるのか？

II.　安全かどうかを判定できる定量的指標はあるのか？

これらの問いを研究によって応え，結果を総合すれば，自動走行システムのコンピュータシミュレーションによる安全性評価方法は構築できる

I. 起き得る走行環境の仮想設定

- 自動走行システムレベル３が最初に導入されるのは自動車専用道．
- 自動車専用道走行中に起き得る，特に，なんらかの自車の走行に妨害となるような走行環境を洗い出す（自動車工業会と日本自動車研究所がなされた仕事）．

実車走行データベースとの連携

- 実際の自動車走行を記録したドライブレコーダのデータベース（ニアミスデータベース）を，社会で起こり得る交通環境条件のデータベースと仮定する．

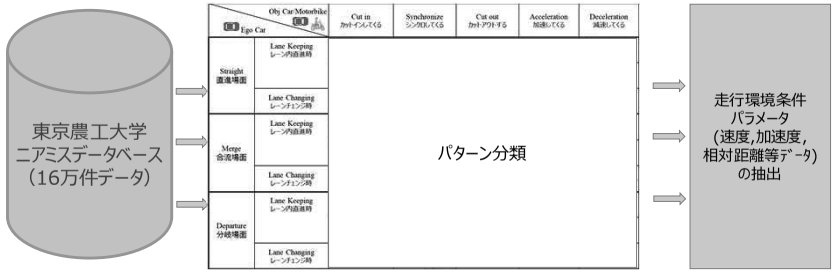

ニアミスデータベース

- 15年間にわたり交通ニアミスデータを蓄積したデータベース．
- 延べ1億km以上の走行中に発生したレベルの異なるニアミス事象のデータを記録．

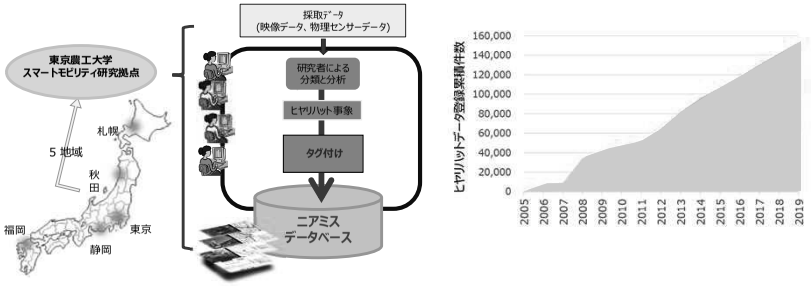

II. 人間ドライバーの安全運転を判定する定量指標の考え方

人間ドライバーの行う安全運転とは

複雑な交通環境でも自動車を安全に走行させることのできるドライバーの特徴:

a. 潜在的に危険な状態を常に予測し，自ら危険を引き起こす又巻き込まれるような行為をしない．=>潜在危険を予知し先読み運転

b. 危険な状態が発生したら迅速な回避行動をとる．

潜在危険先読み安全運転を定量化する

交通環境における危険の分類

（回避性から見た危険の分類）

(認知性から見た危険の分類)	緊急回避は不要		緊急回避が必要	
	物理的回避可能			物理的**回避不可能**
危険が潜在化	Potentially-Normal	Potentially-Normal Preventable	Potentially-Critical Preventable	Potentially-Critical Unpreventable
危険が顕在化	Normal	Normal Preventable	Critical Preventable	Critical Unpreventable

潜在危険度レベルを指標化

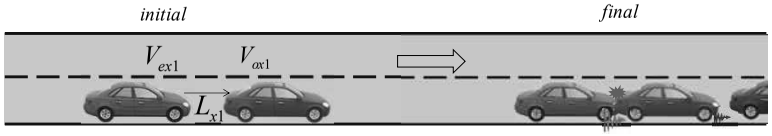

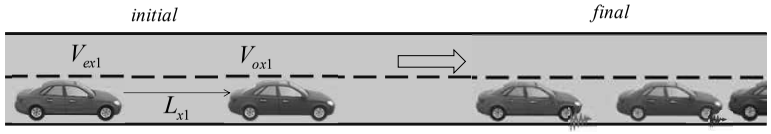

追突パターンの場合の潜在危険度指標の計算方法

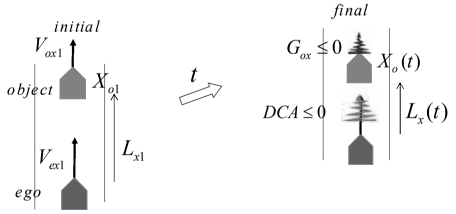

G_{ox} : foreseeable assumption of object vehicle's sudden acceleration
V_{ex1} : ego vehicle initial speed
V_{ox1} : object vehicle initial speed, $V_{ox}(t)$: object vehicle speed at t
X_{o1}: object vehicle initial position, $X_o(t)$: object vehicle position at t
L_{x1} : initial distance from ego to object, $L_x(t)$: distance from ego to object at t
τ: delay of ego acceleration
DCA : acceleration of ego vehicles to avoid rear-end collision

先行車の急減速で追突事故に至った１事象のデータ分析結果

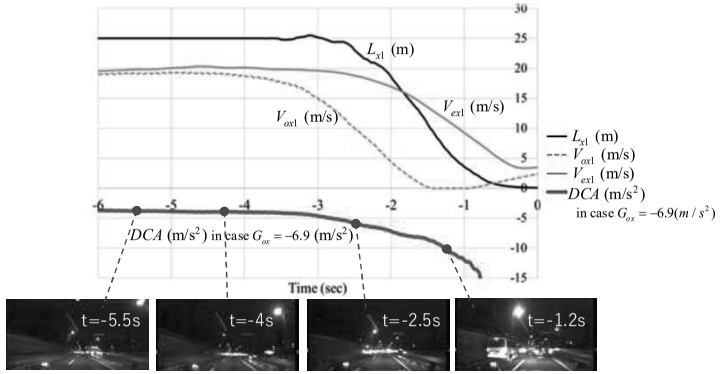

先行車の急減速で「追突事故」に至った１事象における
走行パラメータ変化と潜在危険指標の関係

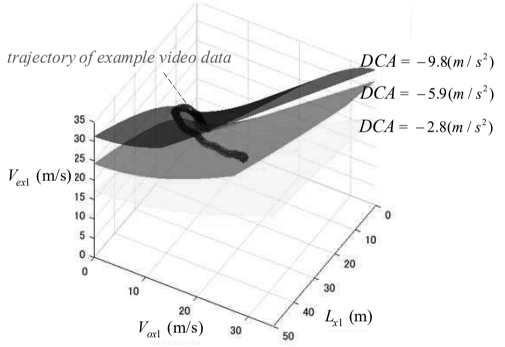

$[D_{x1}\ V_{ox1}\ V_{ex1}]$ space trajectory of example video data

ニアミスデータベースの中から,
先行車の急減速があっても「通常動作で回避できた」事象の,
走行パラメータ変化の分布と潜在危険指標の関係

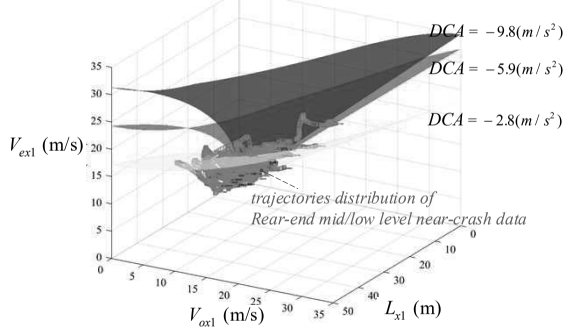

ニアミスデータベースの中から,
先行車の急減速があり「緊急回避して追突を回避した」事象の,
走行パラメータ変化の分布と潜在危険指標の関係

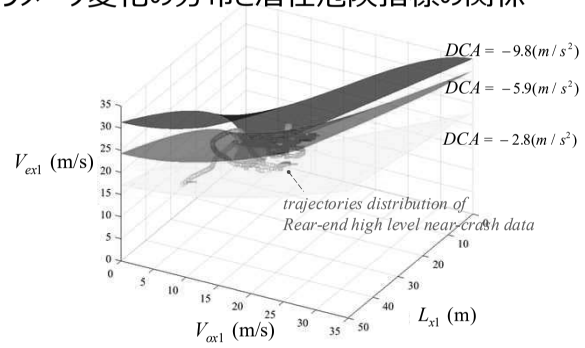

ニアミスデータベースの中から,
先行車の急減速があり「追突に至った」事象の,
走行パラメータ変化の分布と潜在危険指標の関係

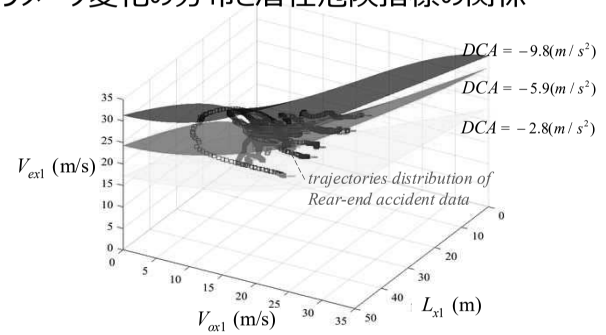

結論とまとめ

- 交通社会で起き得る複雑多様な走行環境を仮想設定する考え方を明らかにした.
- 優れた人間ドライバーが行っている “潜在危険を予知しながら先読み運転をする” という安全運転方法を，追突パターンにおいて定量化する潜在危険度指標を導入し，その計算方法，妥当性を明らかにした.
- 今後，設定された走行環境シナリオの元でコンピュータシミュレーションをおこない，潜在危険度指標値の領域によって安全性を評価する，という自動走行システムの安全性評価法構築に貢献していく.

ありがとうございました.

2020.10.8-9　統計数理研究所

高速画像処理の自動運転への役割

○岸　則政（東京大学）平野 正浩（東京大学）　妹尾　拓（広島大学）

Role of high-speed image processing system for autonomous driving

* N. Kishi（Tokyo University/ JST）, Masatoshi Hirano (Tokyo University),
Tuku Senoo (Hiroshima University)

Abstract－ We propose a high-speed vision system of 500fps to 1000fps, that is possible to detect subtle relative speeds and to enable reliable detection of traffic signals. We are aiming to improve the risk prediction ability in automatic driving by using these solutions.

Index terms－ **high-speed vision system, autonomous driving, risk prediction**

1　はじめに

自動車に搭載されている自動運転のセンサ・障害物検知センサとして，ミリ波レーダや赤外線レーザレーダ（LIDAR），カメラなどが一般的に用いられている．ミリ波レーダや赤外線レーザ レーダは近年技術革新が進んでおり，解像度などの問題点は解決されつつあるものの，データの更新周期に数十から数百ミリ秒要するため，高速な認識が必要な状況に対応するためには，さらなるセンサの進化を待つ必要がある．一方で，毎秒 500 フレーム以上の撮像が可能な高速カメラは，ミリ秒オーダーの限られた時間の中でも環境の認識が可能であり，かつ点群よりもリッチな画像としての計測可能であるため，上述の目的に合った有望なセンサであると考えられる．また、移動、静止時に対象となる移動物体の追従・追跡の面でも、フレームレートの速さから縦方向、横方向の距離分解能が従来のカメラやセンサに比較して格段に向上する利点がある．このことから高速に移動する車を追従する際や、高速移動する車から外界を認識する際有効になると考えられ取り組んでいる．今回は、種々の自動運転関連の応用事例を列記しその可能性を論じる．

2　自動運転への応用事例検討

自動運転における高速カメラの役割は種々挙げられる．具体的には、車両が100ｋｍ/hでの走行であっても、1000フームのカメラでは0.0277mの移動タイミング毎でのカメラ情報を獲得することができる．これはまた、飛び出しくる対象物を1000フームのカメラでは0.0277mの移動タイミング毎でのカメラ情報を獲得することができる．そこで、本稿では、自己位置推定、前車追従の車間距離計測、加えて、重畳車両の識別と車間距離計測を対象に高速カメラでの検出性能向上、ロバスト性の向上について論じる．また一方、無線通信による信号機情報の伝達などが考えられているが、自律的な信号機認識も重要な課題だと考え、この問題の解決方法も論じたい．

2･1 自己位置推定 [1]

自己位置推定は基本的な技術である．特に車両を対象とした自己位置推定では，航法衛星を用いた全球測位衛星シ ステム（GNSS: Global Navigation Satellite System）がもっとも一般的に用いられている．しかし，衛星との通信 が困難なトンネル内や，アーバンキャニオンと呼ばれる高層ビルに囲まれた場所では，精度が著しく低下することが 知られている．こうした GNSS の持つ欠点を補うため，車両に搭載したセンサの情報を利用して車両の移動量を逐次推定し，相対的な自己位置を推定するデッドレコニング（Dead reckoning）が研究されている．また、カメラを用いたビジュアルオドメトリは精度の検出が頑健な典からも近年盛んに研究されている．その大部分は前方に向けられたカメラによって，周辺環境中の移動しない点を基準（特徴点）として自己位置推定するものが多い．しかし，走行中の 車両に囲まれた時のように視野内の大部分が移動する物体 に占められている場合や，トンネル内のように周辺に特徴 となるものが少ない場合または雪面などの特徴に乏しい路面においては，デッドレコニングは連続する撮像画像間の移動量 を積算することで自己位置を推定するため高精度に自己位置推定することが困難である．

そこで、本稿では下向きカメラを用いたビジュアルオドメトリ手法を提案する． Fig. 1 に示すように，車両に下向きに設置した高速ビジョンを用いた相対的自己位置推定を行う．下向きに設置したカメラを用いることで路面を基準とした自己位置推定手法になる．すなわち、自動車などの高速な移動時でもフレーム間の重なりが生じる高速カメラの利点を活用し、通常 3 次元で扱われる移動推定問題を 2 次元に帰着させるこの問題を解決している．具体的には、Fig.2に示すアルゴリズムにより自己位置推定を行っている．まずは、画像間の変形は相似変換を仮定できることを利用し，高精度に推定可能な回転不変位相 限定相関法（RIPOC）[2] を用いて画像間の移動量を推定している．本手法では，画像の周波数領域 でのピーク検出によって回転・並進を推定する回転不変位 相限定相関法（RIPOC）を用い高速カメラの内部パラメータ（焦点距離）や地面からの高さが既知であるとすると，推定した画像間の位置ずれ量からフレーム間での車両 の移動量を計算できる．このようにして得たフレーム間の 移動量を積算することで，相対的自己位置推定を行う．本手法でも，Fig. 3に示す窓関数の適用ROI(Region of Interest)による不連続性の除去，重み付き正規化相互パワースペクトルを利用している．

本稿では，幹線道路上を走行する車両で実験を行ない，手法の有効性を検証した結果を Fig. 4 に示す．ここでは撮影を開始した地点を（0,0）[m]としたとき撮影終了時の位置は（91.35，1.86）[m]であった．現在は提案手法の精度を検証するとともにさらなるロバスト化高精度化に取り組んでいる．

Fig. 1: Downward Camera.

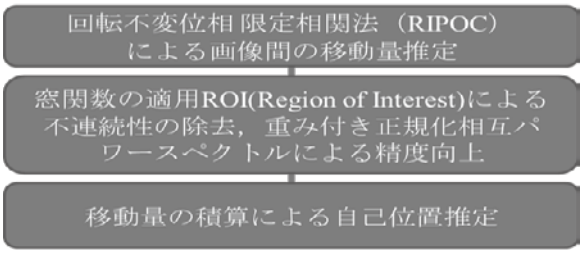

Fig. 2: Algorithm of Self -localization.

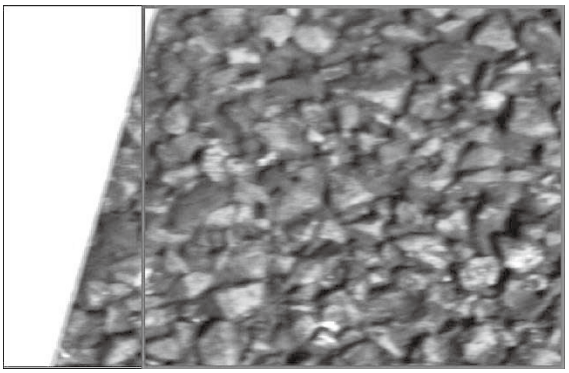

Fig. 3: Raod image and ROI (red frame) setting.

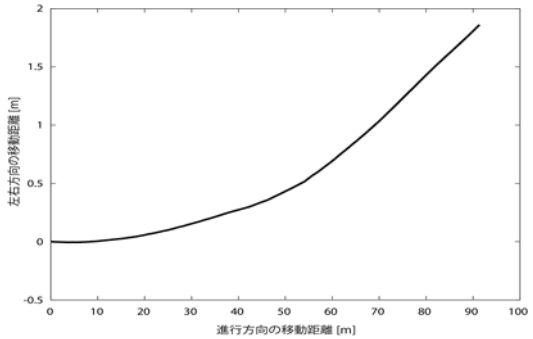

Fig. 4: Result of self-localization.

2･2 500fps でのリアルタイム障害物認識 [3]

ここでは、障害物検知をすばやくかつ確実に検知する技術について述べる．安全な自動運転技術や先進運転支援システムの確立に向け，既に盛んに研究が進められている．しかし，交差点等における出合い頭衝突事故の回避、飛び出してくる障害物の回避では，障害物が視野に入ってから衝突回避行動を取るまでに許される時間が数ミリ秒と非常に短く、安全を保つためにより瞬時に検出する必要と考えている．

本稿では，様々な障害物に対応するために，モデルや学習を必要とせずに障害物までの距離を計算することが可能なステレオビジョンを利用し，Fig.5 に示すアルゴリズムにより 500fps でのリアルタイム高速トラッキング手法を提案している．ここでは、ステレオ逆透視投影(Stereo Inverse Perspective Mapping: Stereo IPM)を用いステレオビジョンで各々計算した逆透視投影像の差分を取ることで路上の障害物を認識する手法[4]であり，学習などの事前処理を必要としない利点がある．加えて、ステレオ逆透視投影は計算負荷が低いという特徴を持つ．高速ビジョンにおける撮像間隔は非常に短く，その間のトラッキング対象の移動量は微小であると仮定できるため，1 つ前のフレームにおける障害物の位置情報を用いることで現在のフレームにおける対象の存在範囲を限定し，大幅な高速化を達成する．このため、逆透視投影像上のヒストグラムに対して検知した物体に対して高速ビジョンによるフレーム間の移動量微小仮定をおくことにより，ヒストグラムの計算範囲を大幅に限定するセルフウィンドウ法[5]を用いることが可能となり，500 [fps]でのトラッキングを可能とした．

Fig. 6 に示す実験環境にて電動 RC カーを対象とした提案手法によるトラッキング実験を行い，500 [fps]でのリアルタイムトラッキングを実証している．トラッキング対象の検知には，IPM 画像対全域に対して計算した輝度の差のヒストグラムからピークを検出することで行った．その結果，Fig. 9 に示すように，時刻 0 において検知されていた電動 RC カーが，0.4 [s]の間に約 70 [cm]移動している様子をトラッキングできていることが確認できた．Fig. 6 は，カメラから見た電動 RC カーまでの距離と方向の時間変化を表すグラフである．距離の推定結果に，撮像時のノイズに起因した変動が認められるが，概ねトラッキングが実現できていることが確認できた．さらに，時間と距離のグラフから実験時の電動 RC カーの最高速度を計算すると時速 5.8 キロであった． 電動 RC カーは 1/10 スケールであるため，実車スケールだと時速 58 キロに相当する．また，Fig.8 に示すように各フレームでトラッキングの計算に要した時間は平均 1.39 [ms]，最大 1.73 [ms]となり，500[fps]のリアルタイムトラッキングが実現できていることが確認できる．

飛びだし対象物の検出とその挙動が素早く検出されることが本方式の強みと考えられる．今後の目標として，画像処理による推定精度の向上，今後移動ロボットの代表的な例である自動車への応用や，視野内に複数物体が存在する場合のトラッキングへの応用が挙げられる．

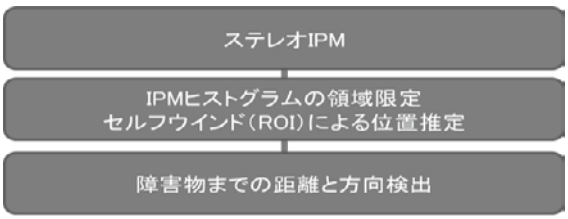

Fig. 5: Algorithm of Obstaucle detection

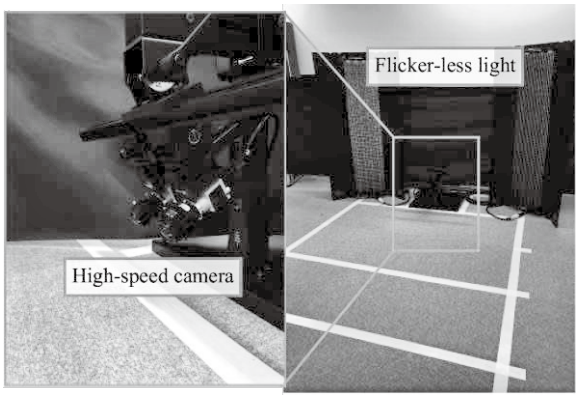

Fig. 6: Experiment settings

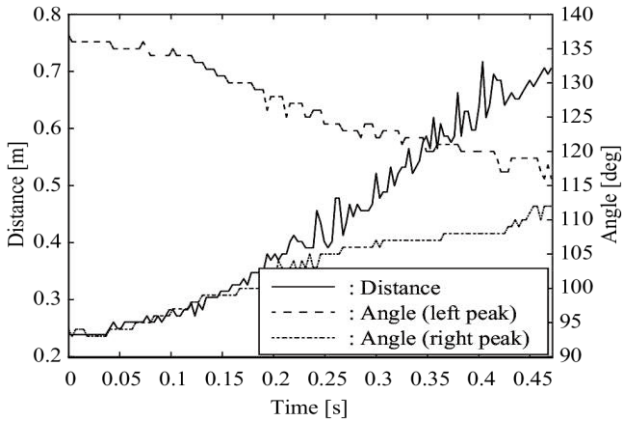

Fig. 7: Estimated distance and direction to the tracking target.

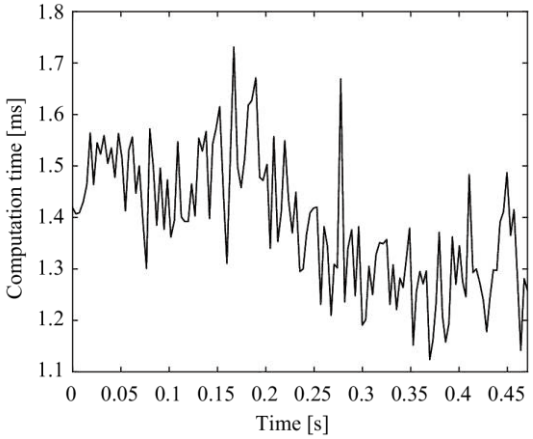

Fig. 8 : Computational time at each frame.

.

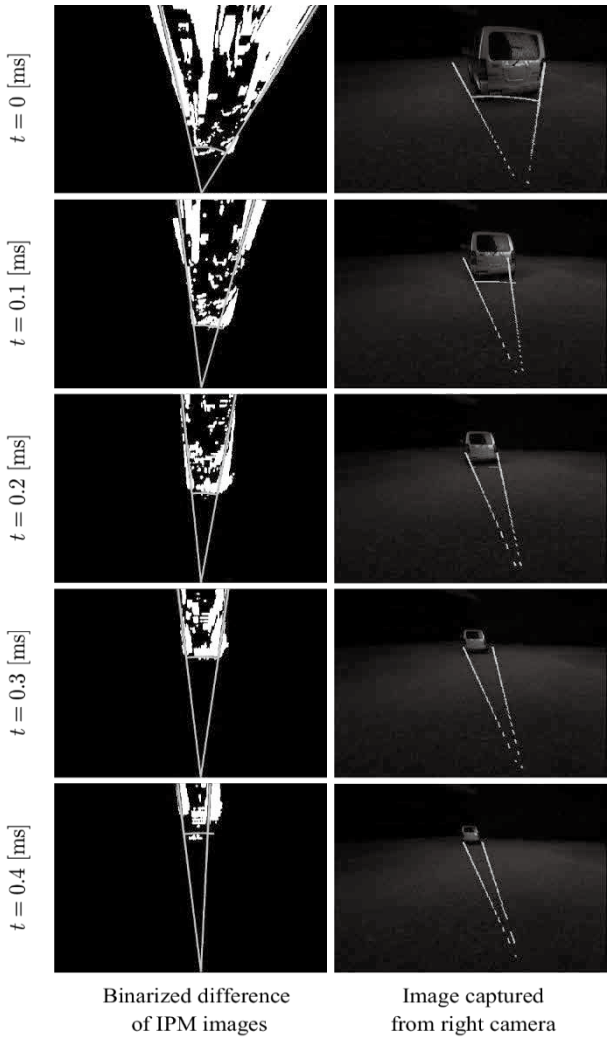

Fig. 9: The RC-Tracking results

The RC car is tracked at 500 [fps].Two yellow lines with their end on the bottom line of the picture represent two side peaks, and another yellow line crossing these two lines is drawn at the estimated distance.

2・3 より正確な前車車間距離および速度推定[6]

上記 500fps でのリアルタイムな障害物検知[3]を発展させ前方車両の挙動のダイナミックスをさらに精度よく推定する手法へと発展させている．自律走行では、周囲の物体を認識し、安全に走行を制御することが重要であり，現在車間距離制御は一般的になってきている．近年、そうした周辺環境認識システムの研究が盛んに行われており、その認識システムには機械学習による画像認識をベースとしたものや、レーザ照射によるリモートセンシングシステムなどが挙げられる．現在トラックの自動隊列走行においては安全なオペレーションのために前方車両と十分な車間距離を取られている．しかし、車間距離を取りすぎるとトラック間への他車両の割り込みによりしばしば隊列走行が中断される．ここで、前方車両のダイナミクス、特に速度情報を高速高精度に捉えることにより、他車両の割り込み柔軟に対応できる車間距離での効率的な走行

が可能となることも期待される．一般的にステレオ画像処理の手法として、三角測量の原理に基づくステレオマッチングやステレオ逆透視投影を用いたものがある．ステレオマッチング手法では、障害物の画像上における対応点を明示的に推定することにより、障害物の位置を精密に計算することができるが、路面と車両の区別が難しく、計算コストが大きいという点が問題点がある．一方、ステレオ逆透視投影手法では、周辺物体に対するモデルや事前知識を必要とせず計算コストは小さいが障害物の推定が安定せずにぶれる点や、トラック等の後方部が接地していない車両では推定精度が低下する点などの問題がある．

前方車両の高速ダイナミクス推定手法は前述の両者の処理を統合し、Fig. 10 に示す高速かつ高精度な前方車両のダイナミクス推定手法を提案する提案手法では、周辺車両の相対位置をロバストかつ高速に推定するために、ステレオ逆透視投影という高速に物体を検知できる手法を用いて周辺車両の大まかな位置を捉え、物体領域を限定する． この領域内で，各 ROI 内で特徴点を検出し、それらの対応の特徴量を BRISK (Binary Robust Invariant Scalable Key points) [7]を用い検出する．得られた左右 2 つの ROI の間で対応する点のペアを見つけるために、エピポーラ拘束による誤対応除去と三次元計測を行う．これにより誤ったマッチングでエピポーラ幾何を満たしていないものは排除される．さらに、ノイズを除去するために、得られた点群の階層的クラスタリングの一種である重心法クラスタリングを行う．これによりクラスタ重心が物体の輪郭を代表する点となっている．その後 Lucas-Kanade 法[8]によるオプティカルフローを用いて得られたクラスタを追跡する．物体表面のクラスタリングされた点群の移動先を計算し、クラスタの集合を更新することで、時間的に安定な追跡が可能となる．

本稿では、Fig.11 に示す実験環境のもと，電動 RC カーを用い前方車両に対しての移動推定を行い、その有効性を検証した．OptiTrack6 台で真値としている．

提案手法で推定された RC カーの認識結果を Fig. 12 に示す．提案手法で推定された RC カーの認識結果を Fig. 10 に示す．図では点群の各クラスタの重心を地平面に真上から投影した点を青の折れ線でつないでおり、緑の数字は各クラスタの要素数を示している．車の後部と側面部に沿って推定されていることがわかる．

Fig. 13では、RC カーをカメラの奥行き方向に往復させたときに、提案手法により得られた推定値に対してカルマンフィルタを適用した値と、OptiTrack により得られた真値とを比較したものである．紫の実線はカメラ系から障害物表面の点群までの地平面上の最短距離を、紫の破線はその真値を表している．また、水色の実線はフレーム間の点群の z 方向(画像の奥行きを正方向)の移動量を表しており、青い破線はその真値を表している．この図から、距離の正確な推定ができたことがわかり、またフレーム間の移動量はその瞬間の速度を表すことから、速度についても正しく推定できていることがわかる．特に本実験で実施したような高フレームレート計測においても各時刻における速度が推定できていることが確認できる．

今後は、さらなる推定精度の向上と高速化、さらには実車映像を用いたトラックの隊列走行への応用の可能性の検証を行っていく．

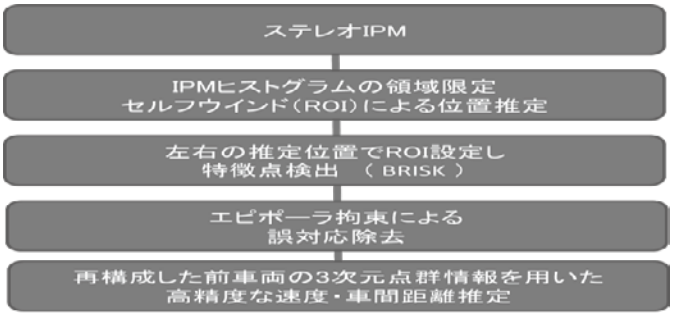

Fig. 10: Algorithm for high speed dyanamics estimation of forward vhiecle.

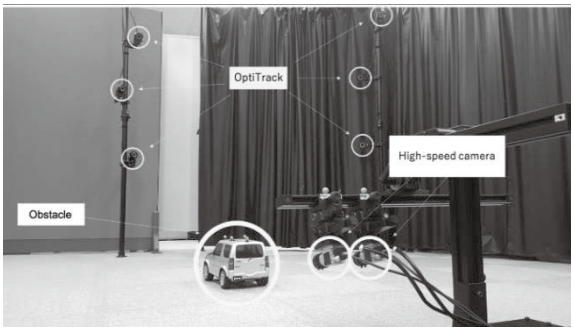

Fig. 11: Experiment settings

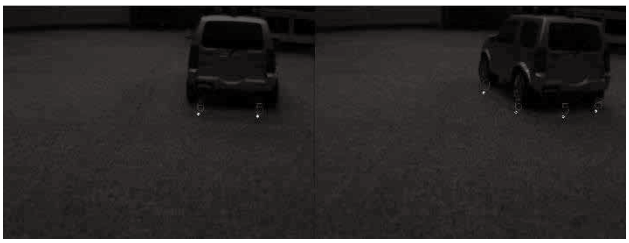

Fig. 12: Result of point cloud detection

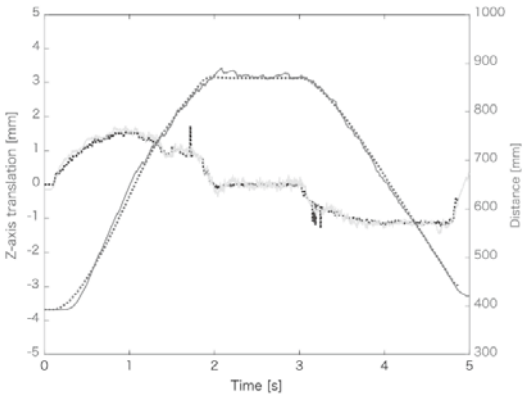

Fig. 13: Estimated distance from the camera to the car along with ground truth by OptiTrack

2･4 重畳車両における距離･速度計測[9]

車両同士が重畳した場合や，車間距離変化によって車両画像の大きさが変化した場合に対してのトラッキングについて述べる．渋滞や前方車の車線変更時において，よりスムーズな発進・停止の実現が期待されている．ミリ波は電波の透過性が高く，前方車と重畳した 2 台前の車両挙動を大まかに把握できるが，現状では認識精度に問題があるため，ドライバーにアラートを出すにとどまっている．カメラと併用することで認識精度の向上を目指す研究もおこなわれているが，距離や速度に関しては検出原理としてミリ波がメインで画像情報は補足的に用いられることが多い．

Fig. 14 に示すアルゴリズムによりステレオ高速カメラのみで正確に距離・速度の計測を実現している．まずは、従来研究[10]で示したように，前方画像に対し深層学習（YOLO）を用い対象物の認識と対象物の Bounding box（BB）の情報を得る．次に処理高速化のために各車両の大きさに合わせた Bounding box（BB）を適切に生成する．これにより，継続して安定した時系列情報が取得可能になり，各車両の距離・速度をロバストに求めることを実現する．また，前方車物体追跡手法である Minimum Output Sum of Squared Error (MOSSE) [11]をベースに改良をおこなう．MOSSE は適応的相関フィルタを用いたテンプレート追跡アルゴリズムである．この手法のポイントは、重畳車両のバウンディングボックス対応として、Fig. 15 に示すように 2 台の車が部分的に重なった時に，左右画像のそれぞれの BB 重畳領域を内包する最小の長方形を単色塗付領域として設定する点にある．面積の変化にロバストとなるように，車間距離を用いて BB の大きさをスケーリングし，BB 内の車両面積の割合がほとんど変化しないように BB を補正する．BB のサイズ変化に伴う計算量増加を回避するため，BB 内の画像を特定の固定サイズにリサイズしてトラッキングする．これにより，BB が大きい場合でも計算時間が伸びることなく MOSSE が適用できるようになる．また、高速カメラの特徴を利用し、サブピクセル精度のトラッキングを可能としている．画像変動が少ない特徴を利用することで，相関ピークの移動量を求めるときに，±3 ピクセルの範囲内でのみ探索を行ことができる．急激に BB の位置が変動せずロバストに追跡を続けること可能となり左右画像の BB の中心位置から三角測量で距離を計測した後，カルマンフィルタによって滑らかな距離・速度の時系列応答を求めことができる．

実験車両両は Fig. 16 に示すように車両のルームミラー付近に高速カメラを 2 台取り付け，天候晴れの日に首都高速道路で実験を行た．左カメラの時系列画像に対して，セダンとトラックの BB をそれぞれ描画した結果を Fig. 1 に示す．自車両との車間距離変化に伴う画像内の車両サイズの変化に合わせて，車両の BB のサイズが適切に設定されていることがわかる．分離状態から重畳状態へ移行した時に，一部が隠れているトラックに対しても本来の車両位置に適切な BB が設いることがわかる．ドリフトも生じずに，初期 BB に設定した車両領域が安定してトラッキングできている様子が確認できた．Fig. 17, Fig18 に，自車両に対する車間距離と相対車速の結果を示す．重畳状態である 3～10 秒付近において，セダンとトラックがある程度の車間距離を保ちながら走行し，各車両の距離・速度が適切に計算できていることがわかる．また，セダンが 11 秒あたりで加速し始め，16 秒付近でトラックを追い越していくことがわかる．この結果と Fig. 1 を見比べると，加速のタイミングで車線変更をしていて，追い越しのタイミングでほぼ横並びの状態になっており，妥当な結果であることがわかる．以上より，自車との車間距離が変化する状況において，BB のスケールが適切に更新され，重畳車に対して滑らかな距離・速度情報が得られることが確認できた．ロバストな分離識別手法を提案した．車両の車間距離や重畳状態に応じて，BB のスケーリングや学習抑制を実装することで，安定かつ高速な追従特性を実現した．同時に，高速ステレオビジョンを用いることで，車間距離と相対車速を推定した．

今後の課題は，重畳割合に対するロバスト性評価，重畳領域に対する学習抑制手法の改善，複数台への拡張などが挙げられる．

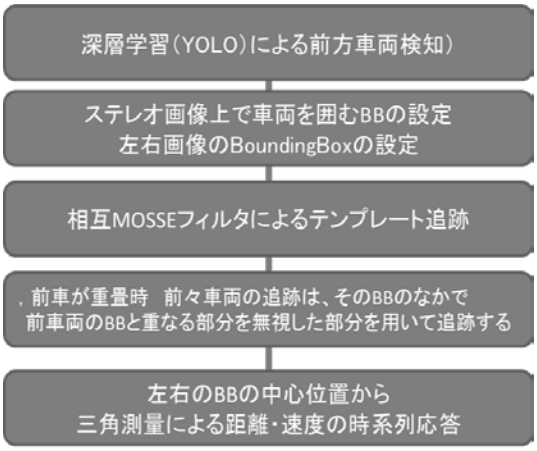

Fig. 14: Estimated distance from the camera to the car along with ground truth by OptiTrack

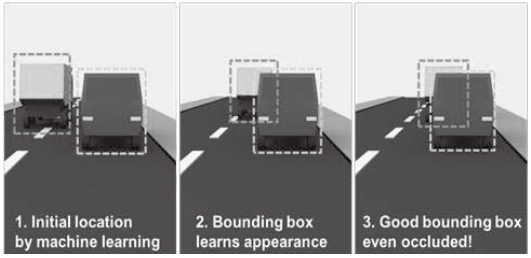

Fig. 15: Bounding Box settings

Fig. 16: Camera setting

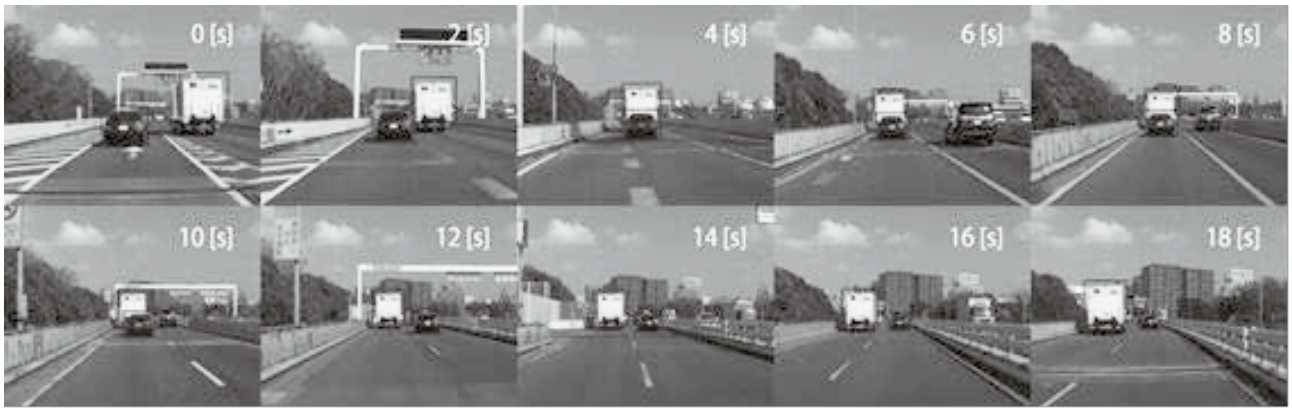

Fig.17: Sequential images with the bounding boxes for two vehicles.

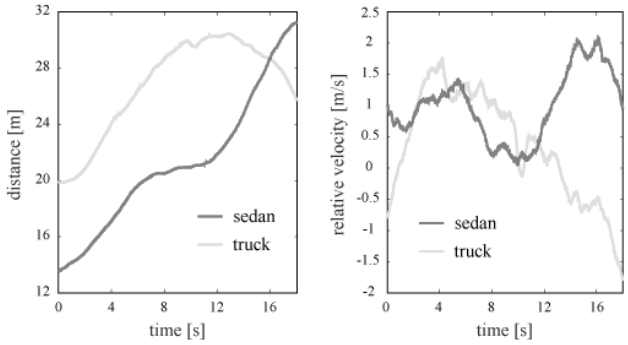

Fig.18: Results of distance and relative velocity.

2･4 信号機認識[12]

交通安全白書[13]によると，交通死亡事故発生件数は交差点とその付近で 46%を占めていると同時に，エコの観点では遠方の信号機の的確な認識により無駄な加減速や急ブレーキを極力なくしたスムーズな交差点通過も可能となるため，運転支援において信号機は主要な情報である．

信号機検出の手法として車両に取り付けたカメラによる画像情報を用いた多くの研究が進められており，大別して 2 つのアプローチがある．一つは，ヒューリスティックなモデルベースであり，信号機の色や形状などの特徴を利用した直観的な識別手法である[14]．もう一つは機械学習ベースであり，ピクセルワイズなセマンティックセグメンテーションによる識別手法が提案されている[15]．また，画像情報を補足する形で，マップ情報と GPS 情報を統合し，地図内の現在位置推定に基づいて環境固定の信号機を検出するなど，事前知識や異種センサ情報を併用することも多い．

本稿では、画像情報による信号機検出として，LED 信号機の時間的点滅パターンを利用した手法を提案している走行中の車両におけるフロント視点のカメラ映像により， 信号機を検出することを考える．LED 信号機は，交流電源 の 2 倍の周波数（東日本：100Hz，西日本：120Hz）で点滅 している．高周波であるため，ヒトの目や通常の CCD カメラ（30Hz）には点滅していることがわからないが，より 高いサンプリングレートのカメラを用いることで検出が可能となる．以前の研究[16]で，150 ms 処理でリアルタイム処理には適していなかった問題を画像処理手法やカメラパラメータ設定の改良により信号機検出の高速化を目指すものである．

信号機認識のアルゴリズム（Fig. 19 ）に示すよう点滅信号の抽出が本質的な処理である．

Fig.19: Algorithm of traffic light detection.

前処理としてはヒューリスティックな処理で非候補領域を除外し，以降の処理プロセスの計算コストを削減する．始めに，静的な画素を除外することを考える．走行時は自車移動に伴う視点変化によって静的な環境に対して画像変化が生じるが，高速ビジョンの特性によりフレーム間の移動量が微小であると仮定し，背景差分によって動きのない画素を候補領域から除去する．これにより，信号機の候補領域を限定する．信号機の点滅周波数より高いサンプリングレートのカメラで画像を取得するため，1 枚の背景差分画像だけでは点滅画素か否かの判別ができない．そのため，Fig. 20 に示すように信号機の点滅 1 周期分に該当する n フレームの画像情報を用いて，点滅画素の確認をおこなう．そして、信号機が存在する領域を限定する

ため、画像にモーションマスク Mi を作成する．フレーム i 番目のグレースケール画像を Ii で表すと，マスク Mi を画像 Ii に適用することで，動きのある候補領域を限定する． 1 フレーム前との差分画像に対して閾値 θB の二値化処理をおこない，二値画像 Ti を得る．そして n 枚の差分画像 Ti−k(k = 0,1,・・・ ,n − 1)に対して OR 演算を実施することでモーションマスク Mi を作成する．前処理後の画像に対して，周期的な輝度変化をしている画素を信号機の点滅として検出する．輝度情報をそのまま利用すると日照条件に影響されやすいため，基準フレームとの輝度差をコード化した時間的二値パターン（Temporal Binary Pattern: TBP）を定義し，ロバストな検出を行う．

TBP は，基準フレーム i と比較フレーム i − k (k = 1,2,・・・ ,n)の差分画像を閾値 θT で二値化し，輝度変化を時間的に列挙したものである．

$$T_i = \{T_{i,i-n}\, T_{i,i-n+1} \cdots T_{i,i-1}\}$$

$$T_{i,j}(x,y) = \begin{cases} 0 & \text{if } |I_i(x,y) - I_j(x,y)| < \theta_T \\ 1 & \text{otherwise} \end{cases}$$

基準フレームは一周期のあいだで輝度がピークである画像を基準フレームと設定した(Fig.20)．信号機点滅パターンは，訓練用データセットから SVM によって求め，{00011}，{00110}，{01110}，{00111}，{01100}，{00010}，{00100}の 7 パターンに決定した．そして、画素領域に対して，形状判定により信号機領域を識別する．ラベリングされた l 番目の画素領域 Cl の面積 Sl と周囲長 Ll を求め，以下の円形度 Dl が閾値 θD 以上の領域を信号機として検出する．

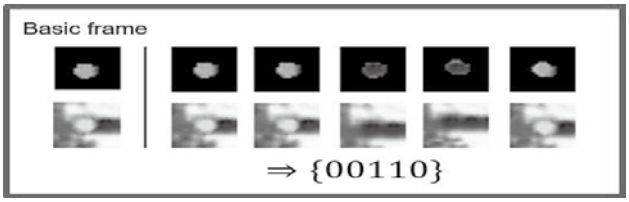

Fig.20 : Signal pattern. .

実際の走行車両で天候晴れの日における都内公道のデータセットを撮影した．ステレオ画像でサイズは 800×680px で，フレームレートは 500 fps である．

Fig.21 に標準的な環境における実験結果を示す．画像内の 3 台の信号機に対して適切にラベリングが付与されていることから，複数台存在する場合でも検出できることが確認できる．

Fig.22 に夜のシーンにおける実験結果を示す．対向車のヘッドライトや道路沿いにある街灯など多数の発光体が画像内に存在しているが，それらは点滅周波数の違いによって誤検出することなく，信号機のみを検出できる．この信号機は 100m 程度離れており，遠方の信号機が検出可能であることを表している．遠方信号機の画像領域は非常に小さくなるため，通常の画像ベースの手法では画素精度の影響により色や形状での判別は困難となるが，提案手法では点滅の時間的パターンを検出するため，遠方信号機の検出に対して優位にあると言える．また，高速カメラを用いることでモーションブラーの影響を軽減できていることも有効的である．

Fig.23 に夕日のシーンにおける実験結果を示す．逆光による飽和画素の影響により，信号機検出に失敗している．ヒトによる視認でも判別が難しい状況であり，提案手法に限らず画像を使った検出手法全般における課題である．

Fig.24 に信号機までのキョリ測手を行った実験結果を示す．

なお、本方式の計算時間は，コード非最適化の状態で平均 12 ms である．以前の研究[16]の計算時間が平均 150 ms であった．よって，本論文では 12 倍以上の高速化を実現し，実用的なシステム構成でリアルタイム処理可能な見通しがついた．現在は、ステレオカメラにより信号機までの距離計測をおこなうことができている（Fig.20）．今後は、矢印式信号機，高速道路の文字掲示板や速度の電子交通標識等への応用も考えていきたい．

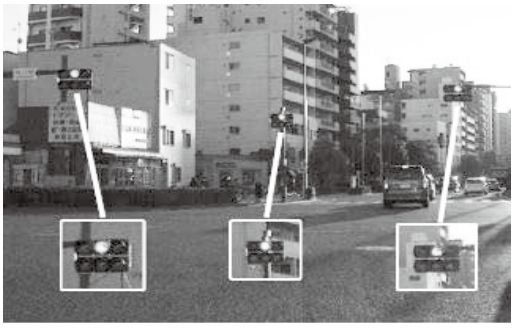

Fig.21: Traffic light in a ordinary scene.

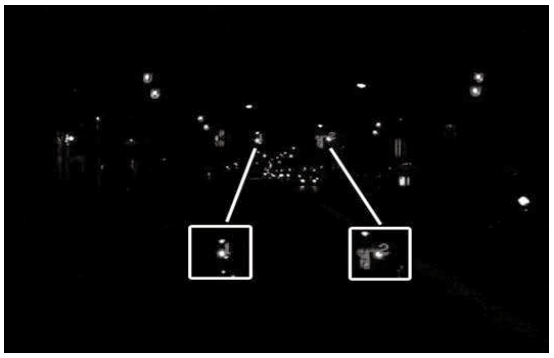

Fig.22: Distant traffic light in a night scene.

Fig.23: Backlit traffic light in a sunset scene.

Fig.24: Distance estimation of traffic light.

3　まとめ

ここでは、高い時間分解能を持つ高速ビジョンシステムによりより幅広い応用ができる自動運転に必要な種々の情報を正確にかつ低レイテンシーで獲得できることを示した．自動運転で、素早い判断、危険予知が必要な場合でも、柔軟な対応ができるためには、素早く状況を判断できること、そしてその動き挙動を正確に計測できることが、今後の自動運転の普及に伴い必要性が増してくると考えている．そこでは、重畳車両の測距、車速推定のところで提案しているが、カメラ映像による機械学習と対象物を確実にトラッキングできる高速カメラとの融合が欠かせないものと考えている．すなわち機械学習による危険予知機能と　高速カメラの見落としなく手レイテンシーで対象物体の挙動を正確に計測・トラッキングすることにより、思ってもみない飛び出しや不測の交通シーンに対しても安全かつ柔軟な自動運転技術に発展させていけるものと考えている．また、ポテンシャルコスト上、低コストでかつカメラのみでシーン理解と正確な計測が可能となる．

今後も、物体識別機能との融合を図り、シーンを理解しながら、必要な対象物をより精度良く計測するシステムに研究を発展させていくことで様々な危険予知の能力を挙げていけると考えている．

謝辞）本研究の一部は国立研究開発法人科学技術振興機構の ACCEL PROJECT の一環として行った．

参考文献

[1] 平野正浩,妹尾拓,岸則政,石川正俊．“下向き高速ビジョンによる自車位置計測法”第 18 回システムインテグレーション部門講演会，（SI2017）pp. 31027-3105，2017.

[2] 青木孝文，伊藤康一，柴原琢磨，長嶋聖．位相限定相関法 に基づく高精度マシンビジョン．電子情報通信学会 基礎・境界ソサイエティ Fundamentals Review,Vol.1,No.1,pp.30-40,2007.

[3] 平野正浩,海保陽太,妹尾拓,岸則政,石川正俊．“ステレオ逆透視投影を用いたセルフウィンドウ法による一般物体の高速トラッキング”計測自動制御学会 SI 部門講演会 SICE-SI2018 予稿集，pp.2953-2956，2018

[4] H. A. Mallot et al. Inverse perspective mapping simplifies optical flow computation and obstacle detection. Biol Cybern, Vol. 64, No. 3, pp. 177-185, 1991.

[5] I. Ishii and M. Ishikawa. Self-windowing for highspeed vision. In 1999 IEEE ICRA, Vol. 3, pp. 1916-1921, 1999.

[6] 海保陽太,平野正浩,妹尾拓,岸則政,石川正俊．“効率的な隊列走行に向けた前方車両の高速ダイナミックス推定”第 20 回システムインテグレーション部門講演会（SI2019），pp.376-380，2018.

[7] S. Leutenegger, M. Chli, and R. Siegwart. “Brisk:Binary Robust Invariant Scalable Keypoint” International Conference on Computer Vision, pp.2548-2555, 2011.

[8] B. D. Lucas and T. Kanade.

“An Iterative Image Registration Technique with an Application to Stereo Vision.” International Joint Conference on Artificial Intelligence, pp. 674-679, 1981.

[9] 妹尾,王充卓，平野正浩，岸則政,石川正俊．“高速ビジョンによる重畳車の距離・速度計測”，第 20 回システムインテグレーション部門講演会（SI2019 ），pp.2200-2202，2019.

[10] 飯島,海保,平野,妹尾,岸,石川．“高速ビジョンを用いた重畳車の分離識別トラッキング”.ロボティクス・メカトロニクス講演会 2019,講演会論文集 2A1-E10.

[11] D. S. Bolme, J. R. Beveridge, B. A. Draper, and Y.M. Lui: Visual object tracking using adaptive correlation filters, Proc. of IEEE Int. Conf. on Computer Vision and Pattern Recognition, pp. 1315-1320, 2010.

[12] 妹尾,王充卓，平野正浩，岸則政,石川正俊．“高速ビジョンを用いた点滅パターン抽出に基づく信号機検出”，第 19 回システムインテグレーション部門講演会（SI2018 ），pp.2913-2915，2018.

[13] 内閣府政策統括官平成 30 年版交通安全白書, http://www8.cao.go.jp/koutu/taisaku/index-t.html

[14] J. Gong, Y. Jiang, G. Xiong, C. Guan, G. Tao,and H. Chen: The recognition and tracking of traffic lights based on color segmentation and camshaft for intelligent vehicles, Proc. of IEEE Intelligent Vehicles Symposium, pp. 431-435, 2010.

[15] M. P. Philipsen, M. B. Jensen, A. Mogelmose, T.B. Moeslund, and M. M. Trivedi: Traffic light detection: a learning algorithm and evaluations on challenging dataset, Proc. of IEEE Int. Conf. on Intelligent Transportation Systems, pp. 2341-2345,2015.

[16] Z. Wu, Y. Watanabe and M. Ishikawa:Hybridled traffic light detection using high-speed camera,Proc. of IEEE Int. Conf. on Intelligent Transportation Systems, pp. 1235-1241, 2016.

東京大学

高速画像処理の自動運転への役割

岸　則政　（東京大学/JST）

平野　正浩（東京大学）
妹尾　拓　（広島大学）

高速画像処理の自動運転への役割

東京大学

技術の特徴と狙い：

カメラのサンプリングタイムを高速(500-1000fps)にして、
瞬時の障害物の検出、対象となる車両の挙動の推定を
可能したり、信号機の確実な検出を可能としたりする事で、
自動運転における危険予知能力を高める事を目指している。

車両周囲のセンシングを
センシングスピードを速める
500－1000fpsの高速カメラで行うことで
自動運転の安全性を向上できないか？

自動車応用での狙い：

東京大学

1）車両位置の正確な把握
　→手がかりのないシーンでの正確な車両制御
2）障害物・対象物の瞬時判断
　→緊急停止時の安全性向上
3）効率の良い交通流の実現
　→高度な停止判断、
　　割込みを考慮したスムーズな走行
　A）車間距離・相対速度・前方車両の姿勢の正確な把握
　B）AIとの融合による交通シーンと複数車両の挙動把握
4）信号機認識
　→インフラレスの信号機認識

1）自己位置の正確な把握

東京大学

手がかりのないシーンでも 正確な車両位置推定

現状：車線認識による走行（レーンキープ）制御
　　GPS,地図による走行路制御

GPSが使えないとき、レーンがないときの
自車両位置の精度向上性能による
走行精度向上を目指す。

スムーズな交差点内通過
スムーズな高架下、トンネル内通過

Downward Camera.

1） 自己位置の正確な把握

東京大学

Algorithm of Self-localization.

回転不変位相限定相関法（RIPOC）による画像間の移動量推定

窓関数の適用ROI(Region of Interest)による不連続性の除去，重み付き正規化相互パワースペクトルによる精度向上

移動量の積算による自己位置推定

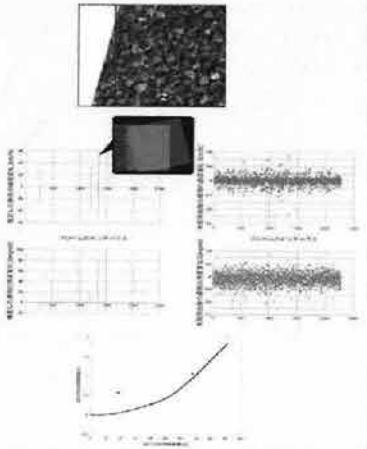

1） 自己位置の正確な把握

東京大学

通過道路

交差点走行

推定した走行軌跡

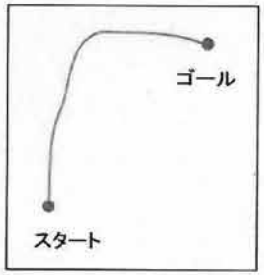

交差点通過実験

東京大学

所望の走行軌跡 ——

と推定した走行軌跡 ——

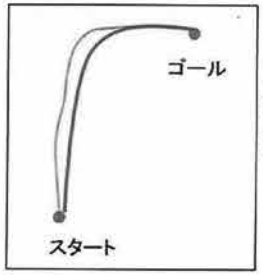

自車両速度、走行軌跡が分かる。
フェードフォワード走行での
正確な走行軌跡制御が可能。
→ 乗り心地向上

2）障害物・対象物の瞬時判断

東京大学

瞬時の障害物検出

↓

障害物・対象物の飛び出しの瞬時判断
→緊急停止時の安全性向上

飛び出しに対する緊急ブレーキは、
0.1secでも早くブレーキが掛けられれば
事故低減につながる。

2）障害物・対象物の瞬時判断

東京大学

Algorithm of Obstacle detection

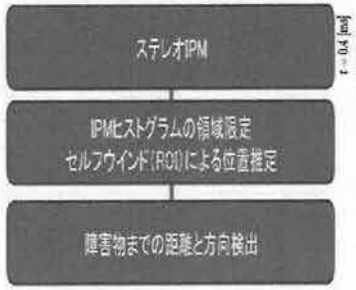

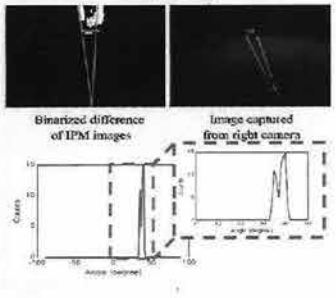

2）障害物・対象物の瞬時判断

東京大学

高速ビジョンに最適化したステレオ逆透視投影により，
500 [fps] 以上の高速検出・トラッキングを実現

カメラ映像　　トラッキング結果

✓ 平均計算時間：1.39 [ms] (≃719 [fps])

2）障害物・対象物の瞬時判断

東京大学

高速ビジョンによる出会い頭障害物の高速検知

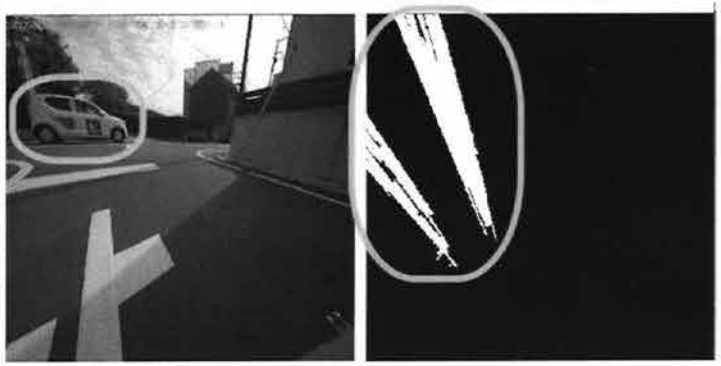

2）障害物・対象物の瞬時判断

東京大学

障害物・対象物の飛び出しの瞬時判断
→緊急停止時の安全性向上

飛び出しに対する
緊急ブレーキは、
約 0.1sec早くブレーキが掛けられ
事故低減につながる。

100msecから10msecで
緊急停止が判断でき
約50cmの余裕できる

車速20km/hの車の空走距離（移動量）	
0.55cm /	1msec
5.5 cm /	10msec
55 cm /	100msec
5.5 m /	1sec

3）効率の良い交通流の実現

東京大学

よりスムーズな車両追従制御を目指す。
・割り込み・追い越しを考慮した追従走行
・停止車両を考慮した車両制御（ブレーキング）

・前方車両との距離
・前方車両の速度
・前方車両の姿勢
・交通シーン
・重畳車両対応高精度距離

A) 車間距離と前方車両の相対速度・姿勢の把握
（特徴点トラッキング）

B) 交通シーンの特定と重畳車両の高精度な距離の把握
（AIと高速画像処理の融合）

3）効率の良い交通流の実現

東京大学

A) 特徴点トラッキング

Algorithm for high speed dyanamics estimation of forward vhiecle.

A) 特徴点トラッキング

東京大学

前方車両の特徴点のトラッキング

前方車両の位置と方向

前方車両との距離
前方車両の速度
前方車両の姿勢
が 推定できる。

A) 実車での特徴点トラッキング

東京大学

3）効率の良い交通流の実現

東京大学

B) AIと高速画像処理の融合

深層学習（YOLO）による前方車両検知）

ステレオ画像上で車両を囲むBBの設定
左右画像のBoundingBoxの設定

相互MOSSEフィルタによるテンプレート追跡

前車が重畳時前々車両の追跡は、BBのなかで
前車両BBと重なる部分を無視した部分で追跡する

左右のBBの中心位置から
三角測量による距離・速度の時系列応答

B) AIと高速画像処理の融合

東京大学

深層学習（YOLO）による前方車両検知）

ステレオ画像上で車両を囲むBBの設定
左右画像のBoundingBoxの設定

B) AIと高速画像処理の融合

東京大学

相互MOSSEフィルタによるテンプレート追跡

前車が重畳時前々車両の追跡は、BBのなかで
前車両BBと重なる部分を無視した部分で追跡する

左右のBBの中心位置から
三角測量による距離・速度の時系列応答

適応的相関フィルタを用いた追跡アルゴリズム
MOSSEを改良

フィルタ更新 $H^* = \frac{A_i}{B_i}$

最適化 $\min_{H^*} \sum_i |F_i \odot H^* - G_i|^2$

$A_i = \eta G_i \odot F_i^* + (1-\eta) A_{i-1}$

$B_i = \eta F_i \odot F_i^* + (1-\eta) B_{i-1}$

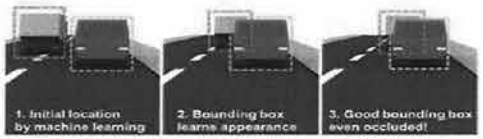

B) AIと高速画像処理の融合

東京大学

実験条件

フレームレート：500 fps
解像度：800 × 600 px
シーン：分離→重畳→分離→追越

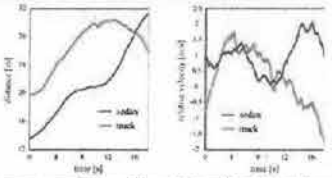

3）効率の良い交通流の実現

東京大学

Approaching & Leaving

車間距離が高速サンプリングでき
スムーズな車間距離制御ができる

3）効率の良い交通流の実現

東京大学

より高精度な車間距離・前車速度推定

Shaking

カメラブレに対しても
ロバストに計測できる

3）効率の良い交通流の実現

東京大学

前方車両の停止/走行状態が分かる　スムーズな車両制御が可能

自己位置推定
（対地車速計）

対象車両の速度

停止判断ができる

4） 信号機認識

東京大学

高速ビジョンを用いた
点滅パターン抽出に基づく信号機検出

インフラレスの信号機認識

4） 信号機認識

東京大学

Algorithm of traffic light detection

信号機1周期分の差分情報で
信号機が存在する領域を限定

限定画像内Temporary Binary Pattenと
学習信号機点滅パタンにより信号機を抽出

（信号機内の色情報を獲得）

ステレオ三角測量により
信号機までの距離と方向検出

2値化

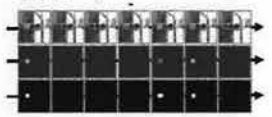

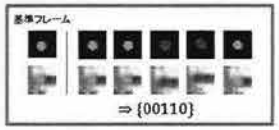

4） 信号機認識

東京大学

実験条件 解像度：800×600px フレームレート：500fps 天候：晴れ

実験結果

□ 計算時間：12ms

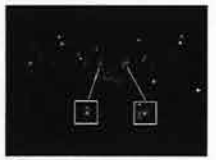

○複数信号機の同時検出 ○夜間遠方信号機の検出 ○逆光により検出失敗

4） 信号機認識

東京大学

4） 信号機認識

東京大学

信号機までの距離を推定

まとめ

東京大学 The University of Tokyo

自動車応用への役割
　高速画像処理(500fps)により低コストな多目的センサを
　提供するっとともに、応用事例に示すような
　自動運転での危険予知能力を高める可能性を示した。

今後:
　機械学習と高速画像処理との融合により、交通シーンに
　適した対象物検出とその拘束トラッキングにより
　さらなる自動運転での危険予知能力を高める事を
　目指していきたい。