

[計算力学部門, 設計工学・システム部門企画 W01100]

# 高度な自動運転を実現するための 数理の現状と課題

(日本機械学会 2021 年度年次大会にて)

日時：2021 年 9 月 7 日 (火) 13 時～15 時

場所：千葉大学 (オンライン開催)

主催：日本機械学会

## 目次

- 0. ワークショップ：「高度な自動運転を実現するための数理の現状と課題」のねらい・・・1  
萩原 一郎（明治大学）
- 1. 自動運転走行車実現のための数理科学・・・3  
萩原 一郎, ディアゴ ルイス, 安部 博枝（明治大学）
- 2. 地方創生のための自動走行車・・・9  
古川 修（明治大学）
- 3. 自動運転協調制御の目指すもの・・・18  
岡村 宏（明治大学）
- 4. 高齢運転者用移動手段  
（運転自動化技術の高齢運転者用車両への活用について）・・・29  
白石 恭裕, 劉 ジェシカ（(株) グローバルアクシス）
- 5. ハイブリッド電気自動車の自動運転へのエネルギー最適制御則の導出・・・35  
内田 博志（福山大学）
- 6. 深層学習を利用したエネルギーベースの  
モデリング・シミュレーションフレームワーク・・・44  
松原 崇(大阪大学), 谷口 隆晴（神戸大学）
- 7. 乗員の状況を把握するための因果の分かるニューラルネットワーク・・・51  
Diago Luis 安部 博枝, 萩原 一郎（明治大学）
- 8. 協調制御利用例・・・61  
安部 博枝, ディアゴ ルイス, 萩原 一郎（明治大学）

※本企画は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(AIMaP)」の協力を得て開催されました。



## ワークショップ:「高度な自動運転を実現するための 数理の現状と課題」のねらい

主催: 日本機械学会  
計算力学部門 & 設計工学システム部門

明治大学 萩原 一郎



■ W01100 高度な自動運転を実現するための数理の現状と課題  
[計算力学部門、設計工学・システム部門企画]  
(日本機械学会 2021年度年次大会での特別行事企画)

◎AIMaP: Advanced Innovation powered by Mathematics Platform  
「数学アドバンスイノベーションプラットフォーム(AIMaP)」  
文部科学省科学技術試験研究委託事業「数学アドバンスイノベーションプラットフォーム(AIMaP)」では、これまでに数学に関わる大学等の研究機関(拠点大学等)が取り組んで来た諸科学・産業界との共同研究等の取り組みを加速するとともに、そこで得られた成果等を集約し、数  
学技術相談データベースを構築し、関係機関のネットワークの中で横  
断的に展開することで、数学と諸科学・産業界との連携によるイノベ  
ションの創出を目指します。

## 明治大学訴求企画『自動運転など自動車産業における数理科学』

**自動運転システム**  
研究対象: レベル3の自動運転

知恵

→

状況認識

→

ドライバー  
運転操作切り替え

※状況認識は、ドライバーに対して適切な運転指示を行う

因果のわかる  
機械学習による協調制御

エネルギー最適制御(EOC)  
でリアルタイム最適制御

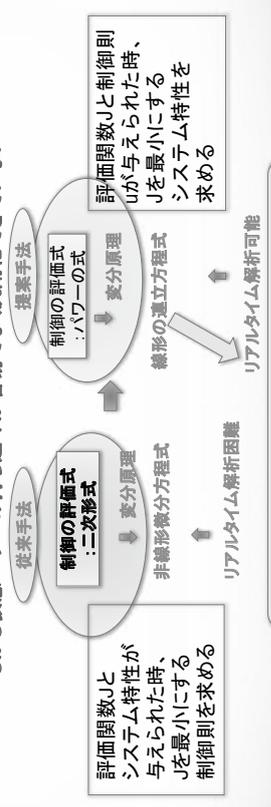
EOC: 差分原理(制御対象系の消費パワーを最適ラランジャン<sup>(\*)</sup>の時間積分の最小化)とその差分条件から得られる制動則を用いてシステム特性を要時間に求める。  
特徴: 位置制御等の目標量の最適化を目的とした外乱力を行方ラランジャン<sup>(\*)</sup>を最小化するようにラランジャンを定式化することで問題を解決する。→ 仮想パワーの導入がポイント  
(\*) 従来の最適制御のラランジャンは2次形式であり、その差分原理は非線形微分方程式を解くことに帰着し、これを軍事コンピュータで実時間に行うことは極めて困難。

**本研究の目標**  
仮想パワーの式の選び方を数理的に明らかにすることで、実時間で得られるEOCの汎用性を向上させる(Ex. 熱線ドライバーの操作を真似た仮想パワーの式をつくと、優れた制動性能が得られている)。→ 阪大MIMDSの高野教授と連携協議中

## 内田先生ご講演

新しい最適制御理論位置付け:

リアルタイムで唯一対応可能なエネルギー最適制御  
しかし仮想パワーの持ち込みが容易でなく汎用化できていない



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

谷口先生ご講演「深層学習を用いたエネルギーベースのモデリング・シミュレーションフレームワーク」が解決に役立つのでは。

- ① 2018年のChenらによるニューラル微分方程式の提案以来、与えられたデータが満たす微分方程式モデルを学習する方法の研究が数多く。ここで微分方程式Aを得る
- 谷口先生らは、深層学習研究の最高位を勝ち取った日本チーム、決め手は異分野研究者のタッグ(日経クロステックより)  
<https://xtech.nikkei.com/atcl/nxt/column/18/01495/122100003>
- ② エネルギー最適制御：評価関数と制御則が与えられた時、評価関数を最小にするシステム方程式B
- ③ AとBの比較から 仮想パワー構築のヒントになるのでは。

5

九大AIMaP便り(2/2)

©W011プログラム司会者：安部 博枝(明治大学)

- ① 自動運転走行車実現のための数理科学
- ② 地方創生のための自動走行車
- ③ 自動運転協調制御の目指すもの
- ④ 高齢運転者用移動手段(運転自動化技術の高齢運転者用車両への活用について)
- ⑤ ハイブリッド電気自動車の自動運転へのエネルギー最適制御の導出
- ⑥ 深層学習を用いたエネルギーベースのモデリング・シミュレーションフレームワーク
- ⑦ 乗員の状況を把握するための因果の分けるニューラルネットワーク
- ⑧ 協調制御利用例

講演②、③、④は自動走行車、自動走行車社会の在り方についての議論。  
 講演①、⑦、⑧は因果の分けるニューラルネットワーク  
 講演⑤は唯一リアルタイム最適制御が可能エネルギー最適制御。  
 講演⑥はうまく利用できればドライブレコーダ上で見られる事故やヒヤリハット。  
 現象の微分方程式化とその現象解析。この対策から仮想的駆動システムの発見につながるのか。



- 萩原 一郎(明治大学)  
 古川 修(明治大学)  
 岡村 宏(明治大学)  
 白石 恭裕((株)グローバルアクシス)  
 内田 博志(福山大学)  
 谷口 隆晴(神戸大学)  
 Diego Luis(明治大学)  
 安部 博枝(明治大学)

関連する特性と数理



7

アンケートにご協力をお願いします。

←アンケート→  
<https://forms.office.com/r/yhbp3M52KM>

AIMaPのHP上でも掲載しております。  
 本企画紹介ページの末尾をご覧ください  
 ←AIMaPホームページ→  
<https://aimap.lmi.kyushu-u.ac.jp/wrp/event/2021a006-1/>



# 自動運転走行車実現のための数理科学

## Mathematical Sciences for Self-Driving Car

○正 萩原 一郎<sup>\*1</sup>, ディアゴ ルイス<sup>\*1</sup>, 安部 博枝<sup>\*1</sup>  
Ichiro HAGIWARA<sup>\*1</sup>, Luis DIAGO<sup>\*1</sup>, Hiroe ABE<sup>\*1</sup>

<sup>\*1</sup> 明治大学 Meiji University

We considered what kind of mathematical science is necessary for the realization of autonomous driving. There are common tasks such as high-speed/precision image processing technology and machine learning technology where causality one is especially important at all levels. For level 3, it is effective to generate models that reproduce the accidents so far and to make accident avoidance technology using energy optimal control theory. For level 4, the mathematical science is important which maximizes the number of remote-controlled vehicles per person and for level 5, mathematical science is important which gives occupants a sense of security By blocking the vibration in the vibration region that affects the ride comfort.

**Key Words** : High-speed/precision image processing technology, Energy optimal control theory, Remote-controlled vehicles, Sense of security, Bistability structure

### 1. 緒 言

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<sup>(1)</sup>。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。ここでは、これらの課題解決を目指し, レベル3, 4, 5それぞれの課題を整理し議論を進める。

### 2. レベル別課題解決のための数理科学

#### 2.1 レベル3に関わる数理科学

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<sup>(2)</sup>。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。ここでレベル3の実現について考察する。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<sup>(3)</sup>。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

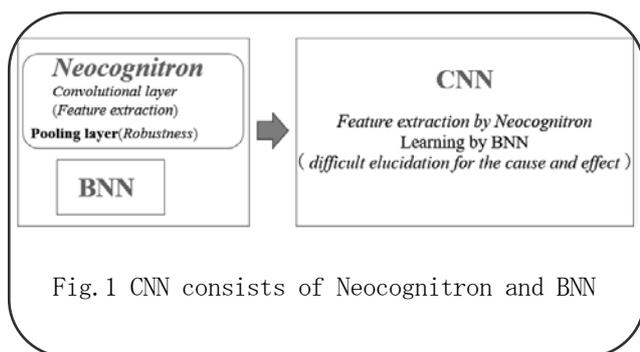


Fig.1 CNN consists of Neocognitron and BNN

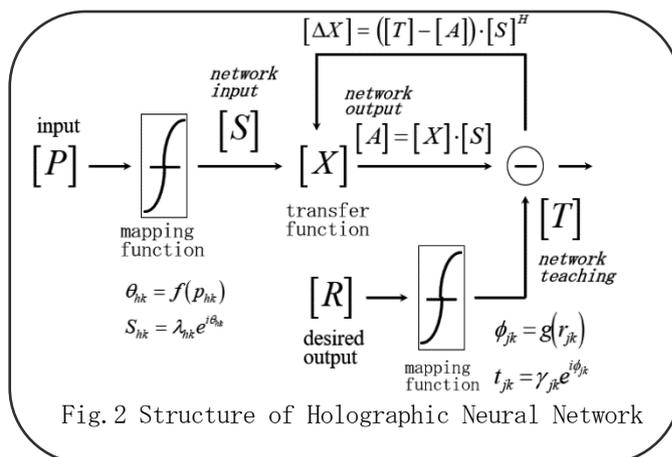


Fig.2 Structure of Holographic Neural Network

えられるが、現在主流の福島邦彦氏のネオコグニトロン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、最適化を始めとする様々な分野に応用し、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ィ推量化理論第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)<sup>(24)</sup>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。更にファジィ推論第Ⅱ類も各パラメータの重みを表現できる。それらの重量を利用する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。

## 2.2 レベル4,5に関わる数理科学

レベル4では遠隔操作を如何に少ない人数で行えるかであるが、ここでも高精度・高速度の画像処理技術のほか、リアルタイム処理可能な機械学習技術が欠かせない。レベル5では、「安全だが安心でない」とよく言われることの対応である。これには、乗員に安心感を与えるべく乗り心地向上のための技術の粋を集めて、しかし、安価に実現することである。そのための数理として、エネルギー最適制御<sup>(4)</sup>、事故のモデリング<sup>(5)</sup>、折紙構造の双安定性を利用した振動遮断<sup>(6)</sup>、などを挙げる事ができる。

## 3 まとめ

レベル3, 4を実現する数理について述べた。特に重要なものは、因果の分かる機械学習とエネルギー最適制御と考えられる。

## 文 献

- (1) 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.
- (2) 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.
- (3) 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
- (4) 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.4(2011-12), pp.259-275.
- (5) 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.
- (6) 萩原一郎, 畳む文化が育む折紙工学 4 展開収縮可能な折紙構造の設計製造, シミュレーション, Vol.39, No.1 (2020-3), pp.46-53.

## 自動運転走行車実現のための数理科学

主催：日本機械学会  
 計算力学部門&設計工学システム部門  
 共催：文部科学省委託事業AIMaP

明治大学 萩原 一郎



## 関連する特性と数理



### 1) 安全

自己位置同定、障害物検知

高速画像処理、高速高精度機械学習

### 2) 安心

乗り心地向上、恐怖心緩和

リアルタイム最適制御(エネルギー最適制御)  
 振動遮断、固有周波数移動

### 3) システムと人間との協調制御

因果の分かる機械学習

## ① 自動運転走行車実現のための数理科学

### Key Words :

高速高精度画像処理技術、エネルギー最適制御、ニューラル微分方程式、遠隔操作、安心感、双安定構造(振動遮断折紙構造)、固有周波数移動:

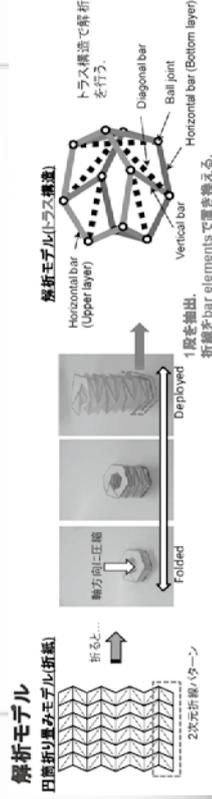
### ／概要／

レベル共通の課題：安全・安心／自己位置推定／障害物検知／信号把握  
 レベル3：ドライバーとシステムの協調制御。  
 レベル4、5：遠隔オペレーターとシステムとの協調制御。

## 乗り心地向上／反転螺旋折紙構造を用いて振動遮断

萩原 一郎、石田 祥子、内田 博志、折り紙をベースにした制振構造、特願2013-220548号 (2013年10月23日)、公開番号2015-81655(2015年4月27日)。

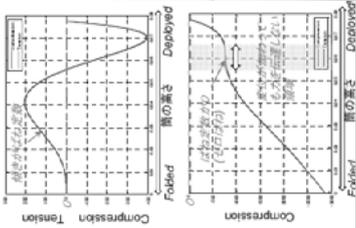
石田 祥子、内田 博志、萩原 一郎、折り畳み可能な構造の非線形ばね特性を利用した防振機構、日本機械学会論文集, Vol.1. 80 (2014), No. 820, p. DR0884



“反転螺旋折紙構造は双安定構造”

## 乗り心地向上／反転螺旋折紙構造を用いて振動遮断

構造全体として見ると...



荷重一変位曲線が非線形なことを強く示す。この非線形性は、衝撃ばねを特徴付ける。

ばね定数が異なる領域で、非線形な振動運動となる。

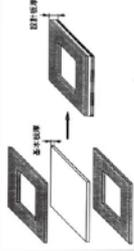
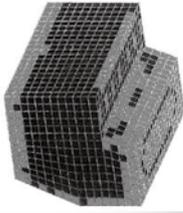
反転螺旋折紙構造は、双安定構造のため、荷重一変位線図でマイナスの剛性の領域。  
 線形ばねとの並列利用で、バネ剛性ゼロの領域が。  
 すなわち、その領域で路面からの振動が伝わらない。

## トポロジー最適化

均質化法1988年(Bendsoe-Kikuchi) ■ 密度法1993年(Tenek-萩原)  
 ■ エネルギ密度法2023年(佐々木-萩原)

Bulletin of the JSME 日本機械学会論文 Transactions of the JSME (in Japanese)  
 Vol. 00, No. 00, 201x  
 固有モードにおけるエネルギー密度に基づき新しい最適化法の開発  
 佐々木 淑恵<sup>1</sup>, 萩原 一郎<sup>2</sup>

No.	Initial Value	Target Value	Result Value
1	6.2	15.0	15.0
2	8.2	20.0	19.1
3	11.7	25.0	25.0
4	14.3	30.0	29.7



最適化による固有値制御

フレームの最適配置 シェル要素の設計領域

## 福島正夫、自動運転車の遠隔監視に資する通信の役割、シミュレーション

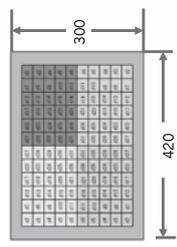


## 恐怖の緩和法

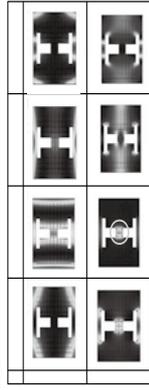
乗用車のレベル5、トラックの隊列走行、小型低速バスなど無人走行車の実証実験が多数。

この中で、レベル5、時速80Kmになれば、安全には達しないが安心ではない。安全と安心はどう異なるのか。恐怖感を助長する周波数帯域があるのでは。

## 2021年に革新的トポロジー最適化技術の開発



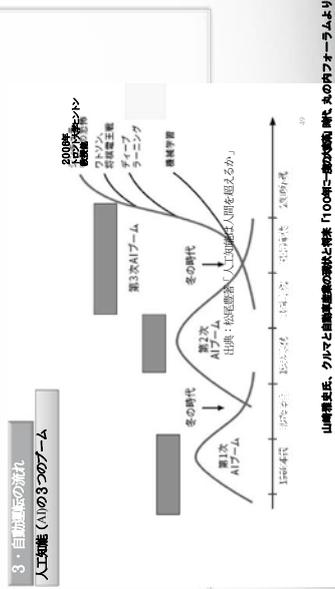
Eigen frequencies	7th	8th	9th	10th
Initial values	8.24Hz	9.37Hz	19.11Hz	19.29Hz
Target values	6.0Hz	6.5Hz	21.5Hz	22.0Hz
Result values	6.74Hz	7.62Hz	20.64Hz	22.29Hz
Design values with holes	6.81Hz	7.08Hz	17.87Hz	19.23Hz



従来の研究の多くはResult valuesで終わっていた。実際の設計は、最適化で得られる振動分布のある周波数以下に穴を開けるもので、折角の最適化結果が生きてこない。  
 振動の原点に戻る、各モードのマスの部分に穴を設ければ固有周波数は上がり、ハネの部分に穴を設ければ周波数は下がるを利用する

AI第2世代から第3世代へ一取り残された因果のわかるAI—  
(2021年5月10日自学会)

第3世代を牽引する~畳み込みニューラルネットワーク(CNN)~

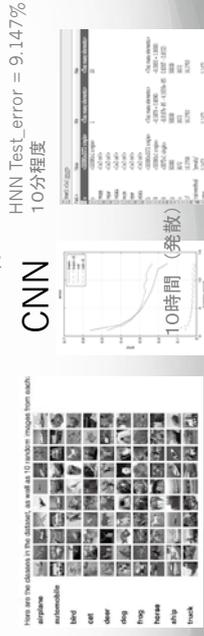


山崎雅史氏、クマルと自動運転車の事故と特集「100年—一部が喧嘩し、時代 別のフォーラムより

探索・推論(第1世代AI)⇒知識(第2世代)⇒機械学習・表現(第3世代)

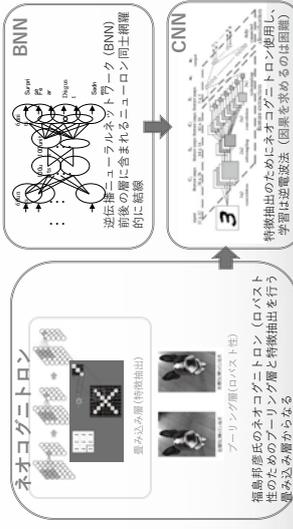
CNN vs HNN – ImageNet上での

- 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力を演じている。
- 一方、我々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)を進めている。
- 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。



第3世代を牽引する~畳み込みニューラルネットワーク(CNN)~

- 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



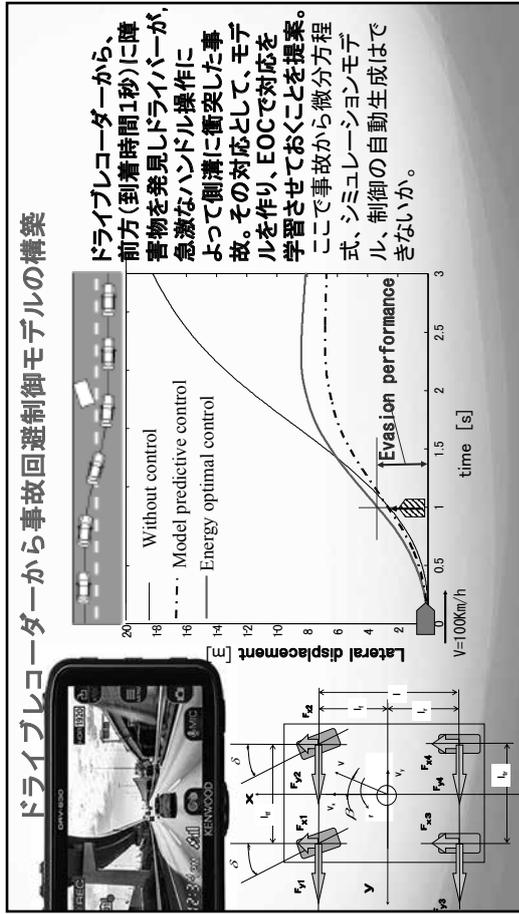
自動走行車に事故やヒヤリハットの対応を学習させる。

ニューラル微分方程式、モデリング、シミュレーションの自動化。

エネルギー最適制御(EOC)で対策。パラメータを替え多くの深層学習のデータに。

2018年のChenらによるニューラル微分方程式の提案以来、与えられたデータが満たす微分方程式モデルを学習する方法の研究が数多く。日本人も谷口先生ら大変御活躍

HNN,ただ一つリアルタイムに最適制御が可能なエネルギー最適制御、ニューラル微分方程式の3点セットで画期的な自動走行技術の開発



### Summary

1. 自動運転はまず安全の確保が第1である。
2. そのため、高速高精度の画像処理技術と機械学習技術が重要
3. そして一段高レベルの制御技術が要求される。
4. これには唯一リアルタイムの最適制御が可能なエネルギー最適制御が有効
5. 但し、仮想機構が必要であるが、これには、Chenらにより提案されたニューラル微分方程式の利用が有効
6. レベル3のシステムとドライバ、レベル4, 5のシステムと遠隔操作車との協調制御には因果の分がるHNNが有効。
7. 構造自体も乗り心地に影響する周波数域、恐怖心に影響を与える周波数域の遮断や共振周波数の域外への移動が有効である。

# 地方創生のための自動走行車

## Automated Driving Vehicle for Regional Revitalization

古川 修<sup>\*1</sup>, ○正  
Yoshimi FURUKAWA

<sup>\*1</sup> 明治大学自動運転社会総合研究所 Meiji University's Institute of Autonomous Driving

For the regional revitalization in Japan, Automated Driving Vehicle is developed as the convenient mobility for elderly people. In this paper, the problems for the realization of Automated Driving services to domestic society are analyzed and the solutions for the problems are proposed.

**Key Words** : Automated Driving Service, Regional Revitalization, Safety Assurance, Business Sustainability, System Design

### 1. 結 言

地方の大きな社会課題として、高齢者への移動手段の継続的な提供が挙げられる。令和元年10月29日に開催された内閣日本経済再生本部主催の第32回「未来投資会議」の基礎資料によれば、地方都市圏（札幌市、仙台市、広島市など地方の41都市）では75歳以上で平日外出時における主な移動手段が自動車だと答えている割合が55%に及んでいる。ところが警察庁交通局「平成30年における交通死亡事故の特徴等について」によれば、75歳以上の交通死亡事故は全体の30%以上に達している。そのために高齢となってからの免許返納者も徐々に増えているが、地方でのバス・電車などの公共交通は利益が少なく、かつ職業ドライバーも不足してきており、高齢者が自動車以外に移動する手段が少なくなっている。そのような状況のもとに、国土交通省「平成29年度国土交通白書の国民意識調査」結果をもとにした現在の住まいに対する不安の調査結果として、「公共交通が減り自動車がないと生活できない」という声が地方では大きく、特に5万人未満の市町村では44.3%の住民がそのように回答している<sup>(1)</sup>。

このような社会課題を解決する目的で、産学官連携組織である「自動走行ビジネス検討会」は過疎地での自動運転の実用化を目指したラストマイル自動走行サービスの導入を提言し、これまでの実証実験の取組と課題、今後の方向性について報告している<sup>(2)</sup>。明治大学自動運転社会総合研究所では、そのような背景のもとに対馬市などと連携して、地方創生のために自動走行車を活用するプロジェクトを推進しており、地方での自動走行サービス事業が継続可能となる独自の自動運転システムを開発し、今年度中に対馬市で社会実験を実施する計画である。本稿は、地方創生のための自動運転システムの社会課題解決へ向けた方向性について論じる。

### 2. 地方でのラストマイル自動走行サービスの社会実装の課題

地方における自動走行サービスは、①幹線道路を走行する自動運転バス②枝線道路を低速走行する小型車両、の2種類に分類されるが、ここでは②を対象として検討する。枝線道路での小型車による自動走行サービスでは、自動走行ビジネス検討会が実証してきた仕様としては、最高速度を12km/h程度に抑えて2km程度の短距離走行で実施することが多い。そして、運転従事者の人材不足対応として、複数台の無人走行車を遠隔で監視員一人が操作を含めた管理を可能となることが必要とされている。そして、今後のラ

ラストマイル自動走行サービスの社会実装へ向けて、限定エリアでのレベル4の無人自動走行サービスを遠隔操作のみで実現させる取組を計画している<sup>(2)</sup>。

地方でのラストマイル自動走行サービスの社会実装するために解決すべき基本要件は、以下と考えられる。

(1) 安全を保証して交通事故を防止すること

(2) 地方の適切な組織体制のもとにサービス事業の持続性が維持できること

本章では、この二つの要件を満たすためのソリューションを論じる。

## 2・1 交通安全の保証

自動走行サービスシステムの失陥や機能不全、遠隔管理ミスなどが起因となって、重大交通事故が発生することは絶対に避けなければならない要件である。そのための体系的でロジカルな保証方法の確立と、国・地方の認可基準などの構築が必要である。

基本的な安全性保証の手法としては、多重防護柵の設置や同一機能要素を冗長系とすることが挙げられる。多重防護柵とは、いろいろな機能不全が生じても衝突や車線逸脱などの交通事故に至らないように、安全維持のために設ける多種類の安全バリアのことを指す。例えば、制御ソフトの暴走に対するバリアとして、ハンドル操舵角速度に上限値を設定して急ハンドルを防止するとか、自動走行ソフトの外側のループとして前方障害物に対する緊急ブレーキ制御機能を追加する、さらに遠隔監視スタッフが常時走行状態を監視して緊急時には介入制御をするなどという安全バリアの設置が考えられる。安全バリアの設計要件としては、システムの単一機能不全があっても、それが原因となって交通事故に至るプロセスを遮断できるように設置されていることが必要である。安全バリアには、ソフトウェアバリア、ハードウェアバリア、遠隔監視バリアの他、交通ルールの特化などの社会制度のバリアを設けることも可能である。

安全性保証を完全に行う目標は、事故リスク予測値をゼロに設定することである。事故リスクを定量的に予測するための手法としては、以下の手法が考えられる。

- (1) 自動走行システムの各機能要素について、様々な環境条件に応じて機能不全となる確率を物理モデルまたは実機の単体実験から求めて、システム全体が機能不全に陥る確率を求める。
- (2) 自動走行システムの全体機能について、様々な環境条件に応じて機能不全に陥る確率を模擬走行シミュレーションから求める。
- (3) 自動走行システムの全体機能について、実車に搭載して自動走行実験を行い、機能不全に陥ることの確立を走行データから分析する。

これらの手法を適時合わせて、事故リスクがゼロとなる保証を行うことが自動走行サービスの開発者に求められる。これらの手法のうち(1)は、単体機能を定量的にモデル化する必要がある、そのためには、道路環境認識手法ができるだけ単純であって、物理モデルで記述できることが必要となる。カメラ画像の解析による道路環境認識は物理モデルでの記述が難しいので、機能不全に陥る確率を求めるには多量な条件での単体実験を実施する必要がある。(逆に、誘導ケーブルを用いた目標コースとの偏差の検知方法では、物理モデルの記述が容易であり、事故リスクを定量的に評価しやすい。それ故、自動走行システムの基本機能はできるだけ単純であることが望まれて、中身をモデル化しにくい高度なAIの導入を避けるべきである。

(3)の実走行実験による保証では、走行距離をどの程度にとれば十分であるかを確率統計学から導く必要がある。市場導入時の自動走行車両の台数と年間の走行距離を設定して、その数値で事故リスクの確率がゼロとなるための、実験走行距離を求めて実証しなければならない。

## 2・2 事業継続性の維持

地方創生のための自動走行サービス事業を継続させるには、そのサービスがビジネスとして成立して、運営する組織の負担が少ないことが必要である。現在日本全国各地で実施されている自動走行サービスでは、導入コストと運営コストが巨額となっていて、社会実装を難しくしている。それ故、地方創生のための自動走行サービスのデザインとしては、以下の要件を満たす必要がある。

- (1) 導入コスト、運営コストを大幅な低減すること。
- (2) 移動と他のサービスを連携させて、付加価値を追加すること。

前者(1)については、まずは自動走行車両のコスト低減があげられる。これまでに各地で行われてきた自動走行の実証実験で使用されている車両は、ゴルフカートを流用する場合と、海外ベンチャーの開発した自動運転バスを用いるケースが多い。ゴルフカートそのものの価格は比較的安価ではあるが、前節で論じた安全性を保証するためには、センサーなどの同じ機能の機器を複数種類搭載して、冗長系を構築する必要があり、自動走行機器搭載と改造コストは車両単体以上にかかる。これらを安価に低減し、安全性との両立を計る自動走行システムのデザインが必要となる。自動走行バスについても同様で、現在1台で1千万円を超すコストが必要であるが、地方行政が複数台導入するためには、さらなるコスト削減が望まれる。

運営コストについても、より安価となるようにシステムデザインを見直す必要がある。現在の公共交通の運営費よりも安価となることが必要であり、そのためには遠隔監視スタッフが一人でできるだけ多くの自動走行車両を管理できるようにすることが必要である。また、自動走行で使用使用するデジタルマップの更新費用の負担も大きい。現在官民連携で進められている自動走行サービスのインフラ基盤となるデジタルマップの仕様は、3次元の高精度のものである。これは道路面だけではなく、周囲の建物や木々なども3次元デジタルマップの要素となっており、特に木々の3次元形状は春夏秋冬の季節によって変化するので、頻繁に3次元デジタルマップを更新する必要がある。現在3次元デジタルマップの生成には、高度な道路環境認識用の機器を搭載したデジタルマップ計測者を走行させて、そのデータをもとに作成される。そのコストは多大であって地方創生のための事業としては負担が大きく、3次元の高精度マップを地方の自動走行サービスに使用することは適切ではない。より簡易でメンテナンスコストが安価である2次元デジタルマップへの転換が望まれる。

(2)の移動と他のサービスの連携による付加価値創出については、地域総合MaaSのデザインのなかで検討していくことが必要である。

### 3. 結言

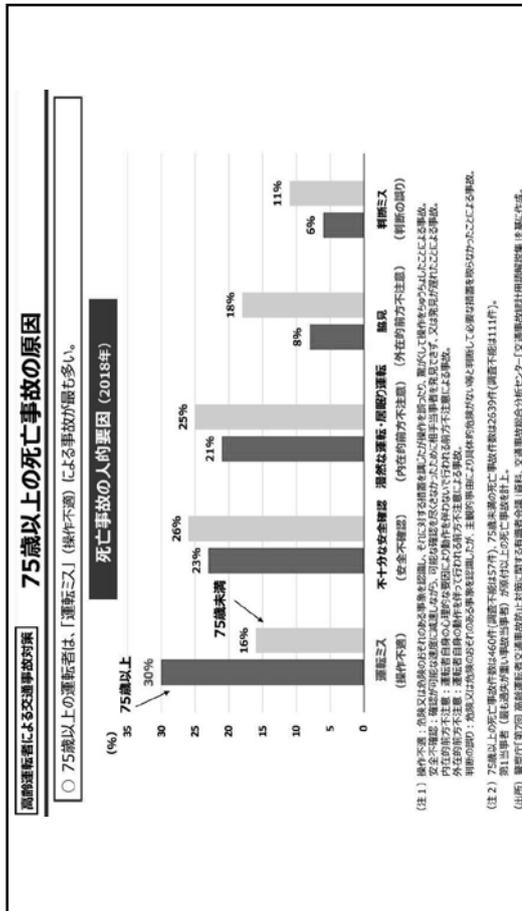
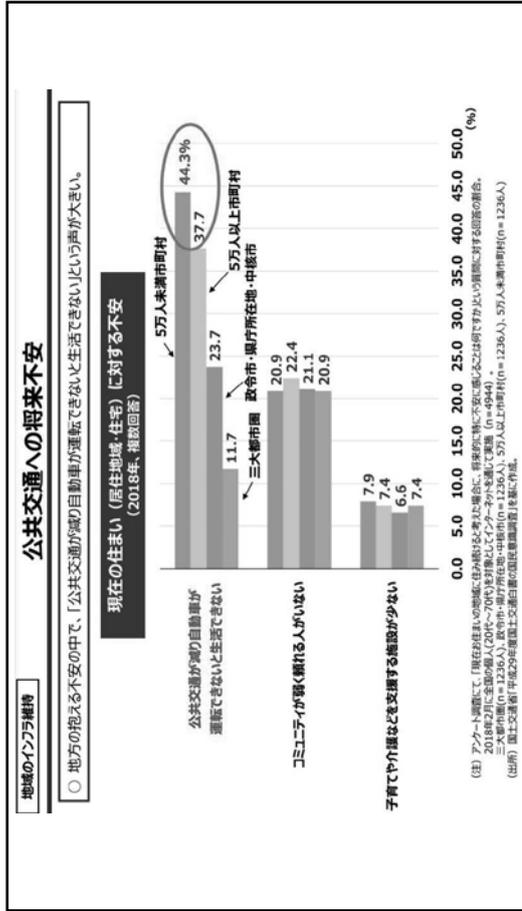
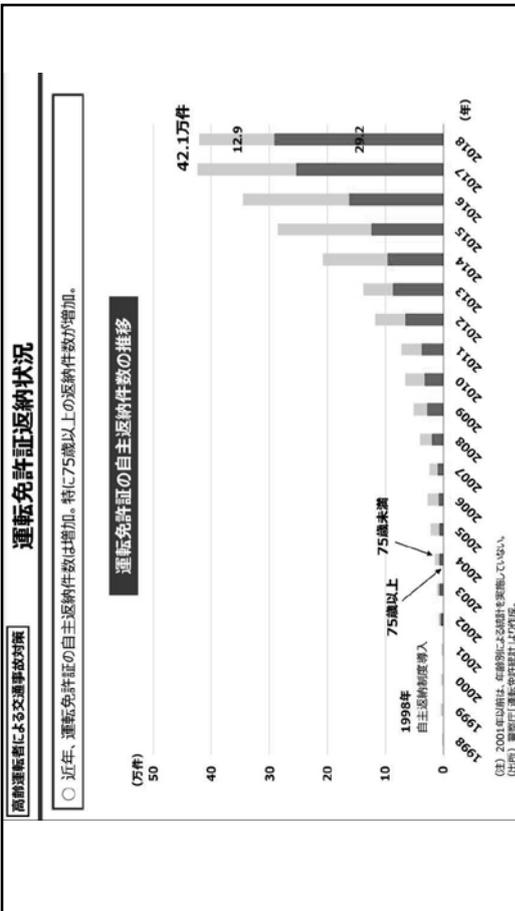
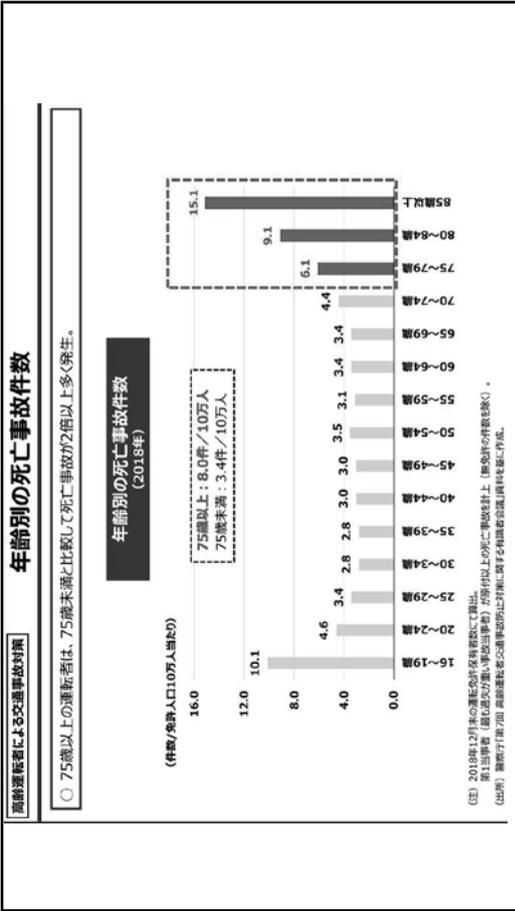
地方創生のための自動走行サービスについて課題と解決の方向性について考察してきた。その結果、今後の社会実装へ向けての解決の方向性を述べてきた。それらをまとめて、以下を提言したい。

- (1) 安全性保証の体系的・定量的な手法の提案と認証基準の策定が必要
- (2) 事業の継続性維持のための導入・運営コストの大幅な低減を目指したシステムデザインが必要

### 文 献

- (1) 内閣官房日本経済再生総合事務局，“第32回未来投資会議—基礎資料”，2019年10月  
<https://www.kantei.go.jp/jp/singi/keizaisaisei/miraitoshikaigi/dai32/siryoul.pdf>
- (2) 自動走行ビジネス検討会，“自動走行の実現及び普及に向けた取組報告と方針 Version 5.0—レベル4自動運転サービスの社会実装を目指して”，2021年4月30日  
[https://www.meti.go.jp/shingikai/mono\\_info\\_service/jido\\_soko/pdf/20210430\\_03.pdf](https://www.meti.go.jp/shingikai/mono_info_service/jido_soko/pdf/20210430_03.pdf)







## ラストマイル自動走行サービスの既存の取組 ～その1

### 路車協調電磁誘導タイプ：永平寺など

#### 誘導ケーブル・磁気マーカー利用

##### 利点

- ① コース追従制御が確実
- ② 車両コストが高くない

##### 課題

- ① ODD外の走行は遠隔管理が必要
- ② 誘導ケーブル設置・メンテのコストがかかる



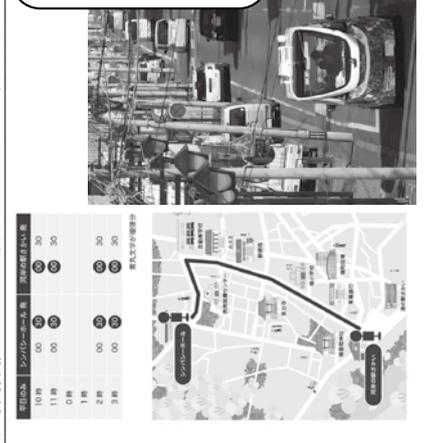
## ラストマイル自動走行サービスの既存の取組 ～その2

### 自律搭載センサー利用タイプ：境町など

- #### 利点
- ① 走行コース・ODD設定の自由度が高い
  - ② インフラ設置のコストがかからない

##### 課題

- ① 安全の保証が難しい
- ② 遠隔監視手法が難しい
- ③ 車両導入コストが高額



## ラストマイル自動走行サービスの最重要3要件

### (1) 価値創出：地域住民がありがたいと感じるサービスの実施

- ～地域社会課題の解決：高齢化・後継者不足・公共交通衰退・産業衰退への対応
- ・高齢免許返納者の移動手段
- ・移動サービスと他のサービスの連携による付加価値創成
- ・遠隔管理員の1:多数の監視

### (2) 交通安全の保証：重大交通事故の完全防止

- ～事故回避のための多重防護柵の設置
- ・システム機能の多重化、フェイルセーフ機能付加、機能安全保証
- ・遠隔管理との安全監視分担

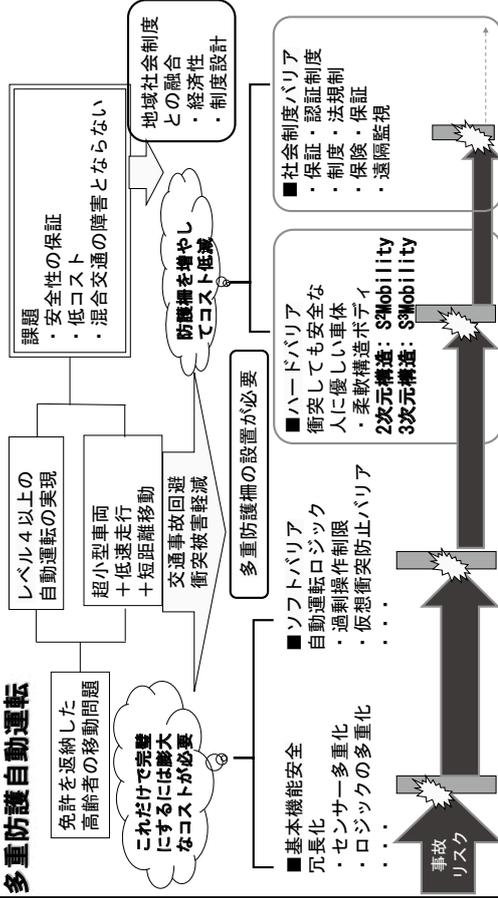
### (3) 持続性維持：地元行政・地元企業体の組織体制・管理運営でサステイナブル

- ～ビジネス性・低コスト（導入・運営）・高付加価値・人材不足対応
- ・低コスト自動走行システムの開発
- ・低コスト管理手法の開発：メンテ費用の削減など
- ・無人走行によるドライバー不足対応

⇒ 3要件を両立させる自動走行システム・サービスの構築が必要

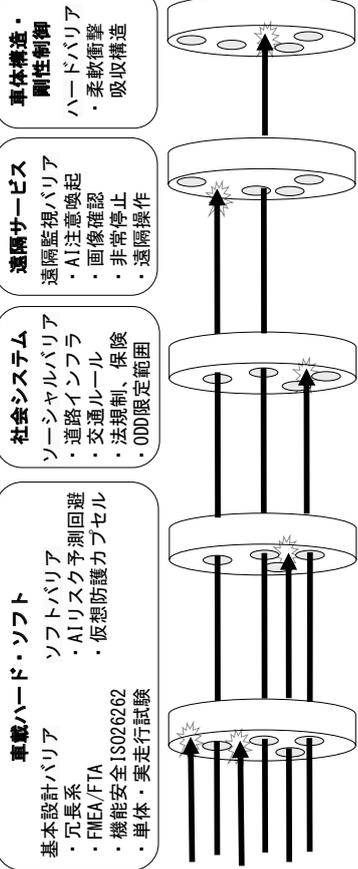
## 多重防護自動運転

免許を返納した高齢者の移動問題  
これだけで完璧にするには膨大なコストが必要



## スイスチアーズモデルによる多重防護層（バリア）の概念

リスク回避責任分担の適切な割当 → 最小限の防護層多重化



## 地方での自動走行サービスの継続的運営維持

- (1) 導入コストの大幅削減
- 1 自動運転システムのコスト低減
  - 2 道路インフラ・デジタルマップのコスト削減
  - 3 ベース車両のコスト低減
- (2) 運営コストの大幅削減・運営管理人材減少への対応
- 1 自動運転システムのメンテナンスコスト削減
  - 2 道路インフラとデジタルマップのメンテナンスコスト削減
  - 3 1:多数の遠隔管理体制構築
- (3) 他のサービスとの連携による移動の付加価値の追加
- 1 消費者への価値創成：医療・観光・親光・買物・物流・防災・防犯などの生活サービスとの連携
  - 2 地方行政への価値創成：医療福祉・ライブライン・環境保全・防災などの行政サービス連携
- ⇒ 自動走行サービス・システムのMaas利用も含めた総合最適デザイン検討が必要

## 地域課題解決・安全保証・継続的運営を面立させる課題

- (1) 導入コストの大幅な低減
- ～日本の地方での利用に適した自動走行システムの自己位置同定機能の最適化
- ① センサー（LiDAR、カメラ、レーダー）の冗長系の最小化
  - ② 遠隔管理とL4車両システムの適切な責任分担
  - ③ 安価で作成できる2次元デジタル地図の利用
- (2) 運営コストの大幅な低減
- ～人件費・メンテナンス費用の大幅削減
- ① メンテナンス頻度の少ない2次元デジタル地図の利用
  - ② 1:多数による遠隔管理員一人あたりの多数車両管理手法の構築
- (3) 自動走行サービスの付加価値の向上
- ～移動とその他のサービスの連携による利便性向上と行政負担の低減
- ① 医療福祉・観光・防災・防犯・物流・買物・地域コミュニティ形成などの地域サービスとの情報連携による利便性付加価値の創出
  - ② 高齢者の外出支援などによる健康寿命向上、道路管理情報の取得などによる地域行政の負担の低減

## 対馬での自動走行サービスデザイン例

**L4自動走行 + 遠隔管理**

- ・ベース車：低価格車両（ゴルフカートなど）
- ・自己位置推定：LiDARによる2次元マップとのマッチング主体
- ・最小限の多重防護層設置
- ・遠隔管理：画像伝送 + AIリスク分析
- ～ 1:多数 を実現
- ～ ODD外走行は遠隔から指示

**ミッション適応型、レベル可変システム**

- ・ドライバー協調運転支援
- ・ベース車：バス、マイクロバスなど
- ・運転支援：AIが道路環境状況・ドライバーの状況に応じて高年齢ドライバーの不得意領域をカバー

## 結言

- (1) 安全性保証の体系的・定量的な手法の提案と認証基準の策定が必要
- (2) 事業の継続性維持のため、導入・運営コストの大幅低減を目指した総合的な自動走行サービスデザイン、システムデザインが必要



# 自動運転協調制御の目指すもの

○岡村 宏\*

\* 明治大学 自動運転社会総合研究所

## The Aims of PCoordinated Control for Automatic Operation

○Hiroshi OKAMURA\*

\* Meiji University MIAD

### 1. はじめに

自動車産業は現在100年に1回といわれる構造変革の中に突入しているといわれている。単なる業務効率化や付加価値付与との従来からの延長上への志向だけでなく、本質的な産業構造に立ち返り、世の中の変化に対応する必要がある。自動車産業のものづくりはすでに頭打ち状態になり、ただ作り続けるのでは、地球規模でのゼロエミッション化への早急な対応とはならない。コネクテッド、自動走行、シェアリング/サービス、電動化のキーワードで表されるCASEの本格化が検討され、環境問題と人間の移動に対するニーズを両立させる次世代のモビリティサービスを目指している。まずは、クリーンエネルギーによる電動車(EV)化があり、バッテリー等の化学プラントのウェイトが増している。また、人が車を買って運転する方式から、モビリティサービスや自動運転を利便的に活用する方式に価値観がシフトすることが想定されている。特に、モビリティに関し、安全な走行環境、モビリティの協調、ニーズとのマッチングには、センサー、情報処理、モビリティ制御等が重要となる。そのためには数理情報やデジタル化の技術が主役の一つに大きくクローズアップされ、それらを取り扱うことで付加価値の集約分野がシフトする。自動車関連産業でも、モノづくりビジネスからデジタルビジネスへの移行が始まっている。

ここでは、将来の自動車自身の付加価値をあげるために、特に、自動運転技術がどのような方向に向かっていくかを考える。

### 2. 自動運転のシナリオ

#### 2.1 自動運転レベルについて

自動運転技術は、上述のような考えのもと世界中で検討が進んでいる。自動運転技術の適用度合を示す指針として、SAEが提案したものが基準とされている。それによると、レベル2までは、運転モードに人とシステムとがお互いに介入することができ、運転者から見ると、運転支援システムである。レベル3は、原則システムが運転し、システム側で、運転ができないと判断すると人即ち運転者に運転を移譲する方式である。システムの故障検知やODD(限定領域)外での運転切替時等がそれに相当する。しかし、システムと人との運転主体の移行プロセスに課題がある。レベル4、5は、原則運転はすべてシステムが行い、走行車両には運転者は必要ない方式である。また、これらの自動運転モードは、走行を認可される道路に関して、通常、ODDなる走行許可の限定領域が付帯される。例えば、最近ホンダが実用化したレベル3の車両は、高速道路での渋滞時(車速は50km/hまで)の走行に限るODDが条件である。

#### 2.2 日本での自動運転への取組

新型ウイルスのワクチンの事例でもそうであるが、日本は新規製品の安全に関しては大変慎重であり、世界の中では、その実用化には保守的である。無人運転車の実現に関して、今までの人による運転と同等の事故率より低い優位性の実績があれば許容する考え方が世界の主流であるが、日本では、ODDで自動運転の適用領域を減らしても安全性を担保できることを目指している。

経産省や国交省が中心とした産学官で構成された自動走行ビジネス検討会等で日本での取り組みのシナリオが検討されてきた。それによると、自動運転レベル4をODDで実現し、無人運転の担保として遠隔監視システムを組み合わせる方式に特化してその実現を目指している。このように自動運転車として、適用範囲を限定して、世界がまだ実現していないレベル4の無人走行車の実用化をめざしている。すなわち、決まった路線や地域を走行する公共交通等による人流や物流に

焦点を当て自動運転技術の実用化をめざし、地域活性化をめざすモビリティサービスシステムにつなげる考えである。そのためには、技術開発とともに、道路等のインフラ・精度整備や日本特有の安全性に係る社会受容性向上への検討が必要となる。ある程度リスクも取りながら開発を進める世界各国の動きと、まずは安全を担保する領域に限定して自動運転システム高度化の戦略をとる日本とどちらが主導権を握るかは興味深いと考える。

### 2.3 自動運転の主たるメリット

自動運転のメリットに関しては、色々な見解や期待が発表されている。それらをまとめてみると、次のようになる。

- (1) 交通事故の削減・高齢者の運転、居眠り疲労等・酒酔い運転
- (2) 渋滞の解消・緩和・一般車との混流で効果は?
- (3) 環境負荷の軽減・不要な加減速の低減、渋滞の抑制と連携
- (4) 高齢者等の移動支援・、高齢ドライバー運転支援・安全
- (5) 運転の快適性の向上・無人運転では快適?、目的までの移動だけ?
- (6) ドライバー不足へ対応・乗務員が不要、遠隔監視員必要
- (7) カーシェアの利便性向上・コストアップの吸収、駐車場への自動回送を自動化
- (8) 無人タクシー・ドライバー不足、人件費レス
- (9) 物流の効率化・ドライバー不足、荷物の受け渡しは?
- (10) 災害時等における緊急対応・ODD 制約の自動運転では無理?
- (11) 保険料が安くなる
- (12) 公共交通への応用・ドライバー不足、低コスト化課題、交通弱者対応
- (13) 駐車場不足の解消・駅への集客が目的?
- (14) 運転免許資格の緩和・高齢者?
- (15) 上限速度制限の緩和・高速道路のみ? 専用道路での車車協調なら
- (16) 生活スタイルの変化・余暇の増大等?⇒移動時間のみ?

これらを見ると、自動車会社がこれらのメリットに対応する付加価値を自動運転車に付与し、ビジネスにつなげるには、単純に車両の提供だけでは難しく、CASEのような地域社会への積極的な取り組みが必要となる。特に車両によるモビリティへの利便性を向上し、顧客に対してそのサービスを受けるという新しい体験をひきだす必要がある。

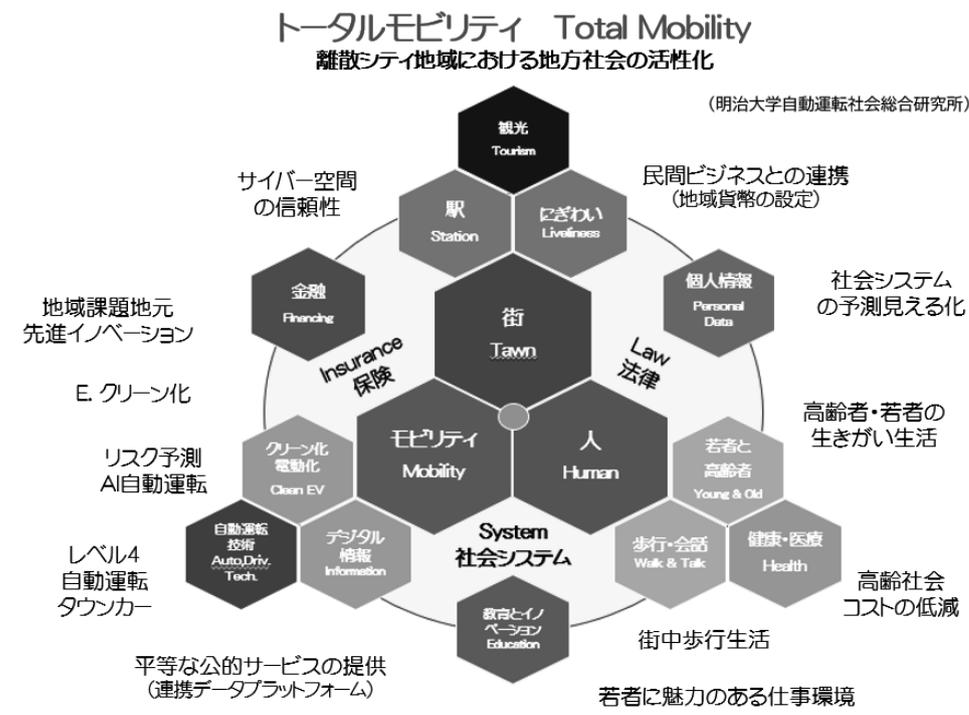


Fig. 1 Total Mobility

## 2.4 トータルモビリティの考え方

図1に、トータルモビリティの考え方を示す。トータルモビリティは、都市だけでなく、離散シティ地域における地方社会の活性化の基本構想を目指している。自動運転の視点から見ると、トータルモビリティでは、基盤要素として、モビリティ、人、街の一翼を担い、それらを補完する要素として、法律、保険、社会システムとの連携も視野に入れなければならない。地域社会でのモビリティサービスとしては、基本となる交通 MaaS (Mobility as a Service) に加え、健康・医療 MaaS や買い物等の商業、観光 MaaS が連携して、初めて社会の活性化が持続的になり、メリットとして定着するとの考えである。

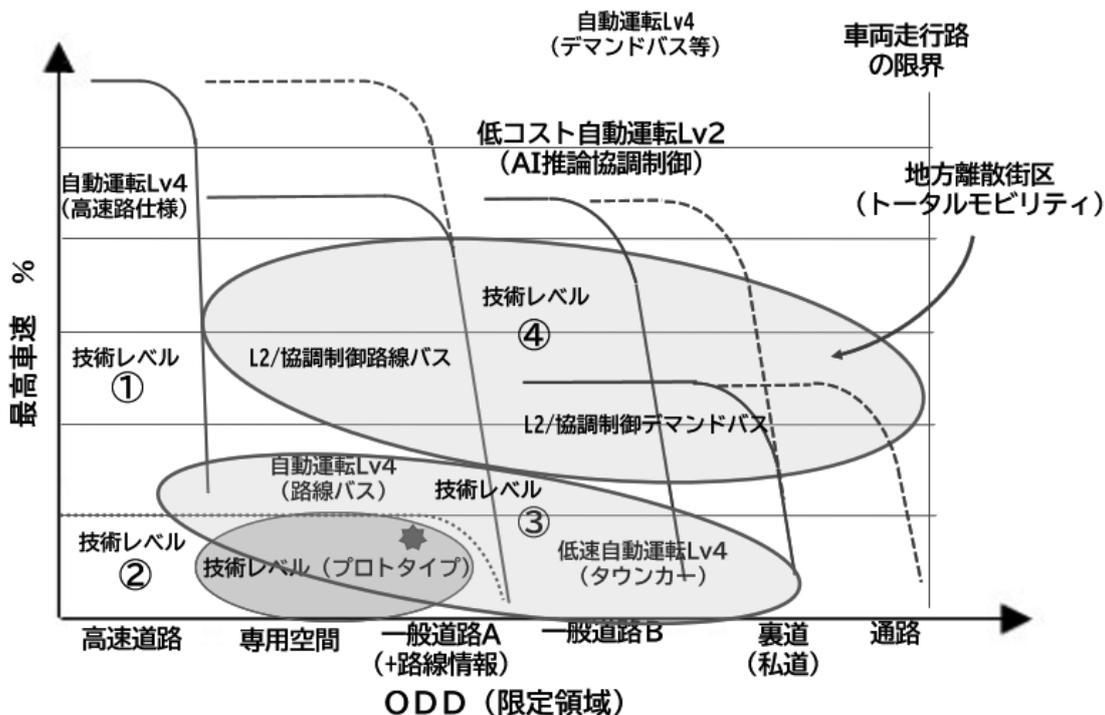


Fig.2 The application area maps for the automatic operationsystem

## 2.5 自動運転へのシナリオ

図2に自動運転車に関する ODD と車両の最高車速との平面での実用化エリアについて考えることとする。ODD 軸は、自動運転が可能な道路環境、条件の制約の度合いを示し、具体的には、自動運転車が走れる道路の種類をあてはめておく。車両の最高車速の軸は、自動運転車が突然の車、人等の接近による衝突回避への対応許容時間に関連するリスクを示すパラメータである。

- (1) レベル①では、高速路のような車専用路は、車が走行する環境が整えられて、衝突等のリスクを低く抑えた走行環境で、自動運転実現に適したエリアである。
- (2) レベル②は、高速路ほどは道路インフラも整備されていないが、自動運転車以外との混流機会が少ないほぼ占有に近い道路環境を極低速で走行するエリアである。
- (3) レベル③では、自動運転車が主体の走行路の ODD とリスク回避可能な低速走行との組み合わせで、技術レベル②を拡大したエリアで、より実用化をめざすものである。
- (4) レベル④は、地域内生活道路をほぼカバーする中速走行域で道路インフラが未整備な一般道路まで拡大するエリアであり、地域のモビリティ生活の多くの部分での自動運転技術の活用が可能となるエリアである。

前述のように、自動運転に関する国レベルのプロジェクトでは、遠隔監視機能を付与して、L4の無人車を実現することに注力している。しかし、その実用化は、図2のレベル③のエリアをカバーできるのが早くも2030年以降である。このエリアまでの実用化では、自動運転の地域活性化への寄与は、かなり限定的であると考えられる。企業にとって、社会からのニーズが中途半端では、自動運転への魅力は引き出すことができない。独自の企業開発努力または国際的企業連携による開発が必要になる。国のプロジェクトでも、L4実現に付随して出てくる自動運転技術は、速やかに社会ニーズへの還元

は行うべきと、言及している。(注)ODD : Operational Design Domain、「運行限定領域」

図2のレベル④のエリアは、自動運転へのリスクが大きいことへの対応として、L2と協調制御システムとの組み合わせがある。これらの適用は、自動車が将来すべてL4になると想定すれば中途半端となるが、自動車の持つモビリティへの柔軟性を求めるニーズの大きな潮流への対応として将来とも必要であると考えられる。

現状での地方地域のニーズに目を向けると、ODD限定のL4無人車の導入も必要であるが、地域全体にできるだけ早く実現するような自動運転L2の協調制御は重要であり、地域からのニーズも強い。

### 3. 自動運転での協調制御

自動運転のために配慮すべき要素は数多くあり、基本的な構成要素と共に各々の属性や関係性は複雑な構造を持ち同時に多様性に満ちている。また、人・道路という機能制約と交通環境等の社会ルールが影響してくる。これらの多くの情報の取得や蓄積によるデータ構造の設計と制約・ルール等の動的挙動に関する制御則の最適化が求められる。自動運転が地域社会で普及するには、従来の有人運転に対するどのような優位性があり、リアルタイムの対応が求められ、コストを含めた実用化に耐えられるシステムづくりが必要である。これらを総称して協調制御と呼んでいる。情報構造の把握とターゲットへの最適化には、情報のセンシングから数理工学的処理まで幅広い手法とAIによる最適化手法と柔軟に且つリアルタイムに対応する手法が求められる。

#### 3.1 車と周辺空間との協調制御・情報構造の構築

##### 3.1.1 周辺空間・データ構造の設定

###### (1)対象物の空間位置 Map

- ①精密 3DMap 等・路車協調，データメンテナンス必要
- ②動的相対位置・車車協調，群制御(含，隊列走行，CACC 等)
- ③ダイナミック Map・静的位置への変換

###### (2)危険要因(リスクポテンシャル)Map

- ①顕在的・対象物挙動からの推定
- ②潜在的・対象物挙動ゆらぎの可能性からの推定，(含，ヒヤリハットデータ集積)

##### 3.1.2. 協調制御・ストリーム推論(最適化問題)

###### (1)リアルタイム軌道補正

- ①衝突回避予測システム
  - ②先読み運転(Shared Control)・リスクポテンシャル図
- (2)速度，路線，ルート制御・飛び出し等の衝突回避マージン考慮
- (3)ハイブリッド・所要時間，乗り心地，燃費等を含める最適化

##### 3.1.3. 応答速度・許容遅延時間

- (1)ダイレクト応答・制動距離，瞬時回避可能ルートに対応
- (2)顕在的リスクへの予知応答・人の応答可能速度並みが目標
- (3)潜在的リスクへの走行プラン設定

##### 3.1.4. ECUの演算システム

- (1)車載オンボード・AI演算可能?
- (2)通信系伝達による固定サーバー(含，遠隔操作，監視)・通信系の遅延，5G
- (3)ハイブリッド型・データ駆動型 AI と理論知識型 AI の使い分け等

#### 3.2. 車と人との協調制御・HMI (Human Machine Interface)

##### 3.2.1. 遠隔監視，運行管理システム

- (1)1:Nでの無人自動運転車の遠隔監視・運行管理の支援
- (2)搭乗者，乗降客，車外周辺の人等との協調支援

##### 3.2.2. 有人自動運転システムへの対応

- (1)高齢ドライバー等への運転支援システム・低コスト普及型指向も ➡ リスク認知遅れ，動作移行遅れへの対応
- (2)リスク回避支援システム(含，ストレス解消，体調異変対応等)

## 4. まとめ

4.1 (自動運転システム)⇒ドライバー役割の肩代わり⇒(協調制御)

4.2 認知・処理(ドライバー相当)の演算速度： (許容遅延時間)

- (1)ダイレクト応答・制動距離、瞬時回避可能ルートに対応 短い
- (2)顕在的リスクへの予知応答・人の先読み速度並みが目標 中位
- (3)潜在的リスクへの走行プラン設定 長い

⇒(演算処理時間+データ通信タイムラグ)とのマッチング重要

⇒ODD: 許容走行速度に影響 4.3. 認知対象物の特性の抽出・AI 画像処理が必要, 演算処理速度も問われる

(1)移動体の特定: 人, 動物, 自転車, バイク等の混流

(2)エリアのリスク抽出: 道路情報, 交差点・ヒヤリハットパターン等の抽出

⇒因果関連の見える化・AI への信頼性, リスク AI 規制対応

⇒ODD: 走行可能な道路環境に影響

4.4. 目標: ODD(走行速度, 道路環境の制約)下での Lv4 無人自動運転

⇒現状では, 実用レベル下限へのチャレンジ⇒制約の緩和へ展開

⇒ドライバー不足対応へのニーズが強い

4.5. 地方離散シティ地区では,

⇒高齢社会: 自家用車利用主体⇒交通弱者増加/公共交通の利便性向上

⇒低コストの(Lv2 と AI 推論協調制御)も早期普及⇒支線 MaaS 対応

## 参考文献

- 1) 西野 智博: 自動車を取り巻く現状と電動化の推進について, 第7回 ESI シンポジウム(交通の電動化への選択とエネルギーの融合を考える), 2020/08/04
- 2) 国土交通省: オートパイロットシステムに関する検討会資料, 国土交通省 自動運転における損害賠償責任に関する研究会資料
- 3) 小木津武樹: 自動運転革命, 日本評論社
- 4) 永井正夫: 国プロとしての運転支援/自動運転システム, 計測と制御, 第54巻第11号, 2015,11
- 5) 我妻広明: 人工知能による運転支援・自動運転技術の現状と課題, 計測と制御 第54巻第11号, 2015.11
- 6) 高田広章, 佐藤健哉: ダイナミックマップ, システム/制御/情報, Vol.60 No.11, 2016
- 7) 萩原一郎, ディアゴ ルイス, 安部倍博枝: 因果のわかる機械学習による協調制御, 第11回横幹連合コンファレンス, 統計数理研究所, 2020.10.8
- 8) 園田成弘, 大前学: 自動運転車の円滑な走行を実現するための空間情報基盤を介した協調走行に関する研究, 自動車技術会論文集, No.20164552
- 9) 我妻 広明, 市瀬 龍太郎: 自動運転用危険予測装置へ誤オントロジー導入誤方策と課題, The 30th Annual Conference of the Japanese Society for Artificial Intelligence, 2016
- 10) 井上秀雄, 「高齢者の自立を支援し安全安心社会を実現する自律運転知能システム」の研究, 最新研究情報, 神奈川工科大学 HP
- 11) 前田健太, 児島隆生, 横山篤: 市街地での自動運転に向けた速度制御手法の開発, 自動車技術会論文集, Vol.47 No.4, 2016.4

□

2021.09.07

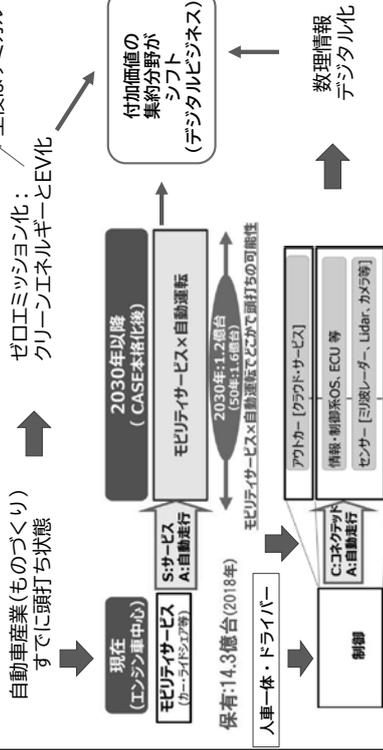
JSM2021年度年次大会ワークショップ  
W01100高度な自動運転を実現するための数理の現状と課題  
設計工学・システム部門企画

## 自動運転協調制御の目指すもの

明治大学自動運転社会総合研究所(MIAD)  
客員研究員 岡村 宏

## 自動運転に求められるものとは？ 無人自動運転のシナリオ

100年に一度の自動車産業の構造変化  
→ 官民協調でCASE対応が必要



## CASE本格化のタイミングには大きな不確実性

● その中で、足下の収益性を高め、先行開発投資を戦略的に進める必要あり。



2020/08/04第7回 E5シンポジウム(交通の電動化への選択とエネルギーの融合を考える), 「自動車を取り巻く現状と電動化の推進について」, 経済産業省 製造産業局 自動運転課長補佐 西野 智博

## 自動運転の社会的課題について (日本学術会議提言, R2. 8. 4)

- (1) 移動の自由と安全の確保
- (2) 人間中心の設計概念が重要, 総合的検討が必要
- (3) 安全性や機能性の人間機械協調の設計視点
- (4) 将来社会のグラウンドデザインの実空間での大事な課題
- (5) 自動運転は社会デザインの一部として設計
- (6) 超高齢社会の課題解決
- (7) 地域特性に応じた取り組みが必要
- (8) エビデンスベースで行うべき
- (9) 実証データの整備, 車載のシステム作動記録装置の設置
- (10) 学際的かつ国際的な価値観や倫理観をも射程
- (11) 他分野とのデータ共有も踏まえた横断的検討をすべき
- (12) 人文社会科学的な価値観や倫理観をも射程
- (13) 基盤的取り組み・法整備をすべき
- (14) 保険制度, 責任の所在などの検討
- (15) 個人情報保護の扱い方, セキュリティのあり方,
- (16) 人材の発掘と育成及び研究開発につなげていくこと
- (17) 文理融合学際領域の人材育成が必要

車と人 (人間中心)

車と社会 (社会貢献)

車と機能 (見える化)

多面性

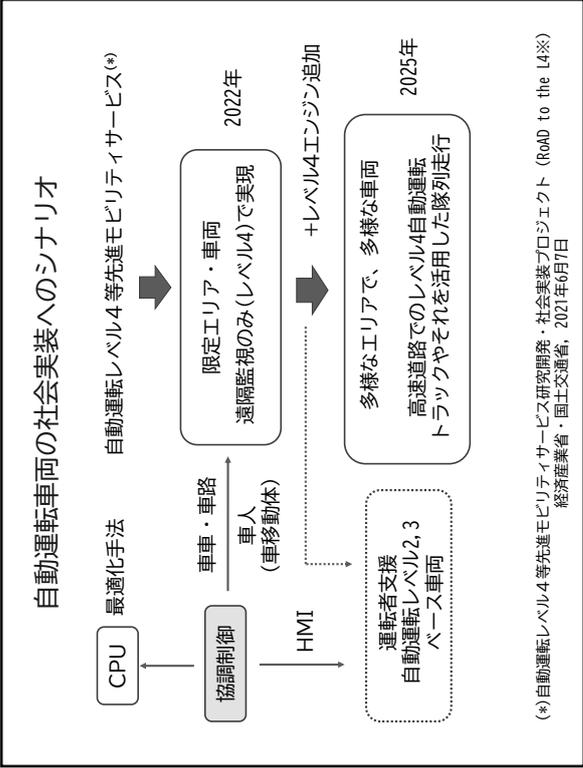
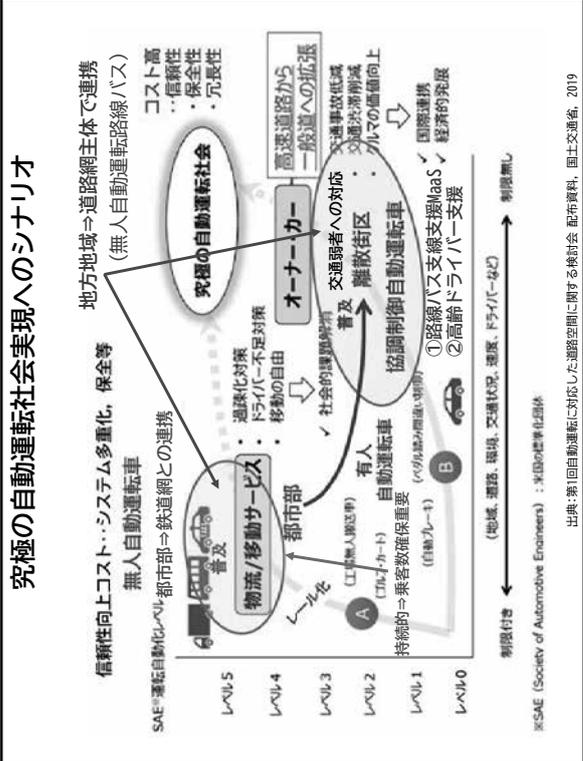
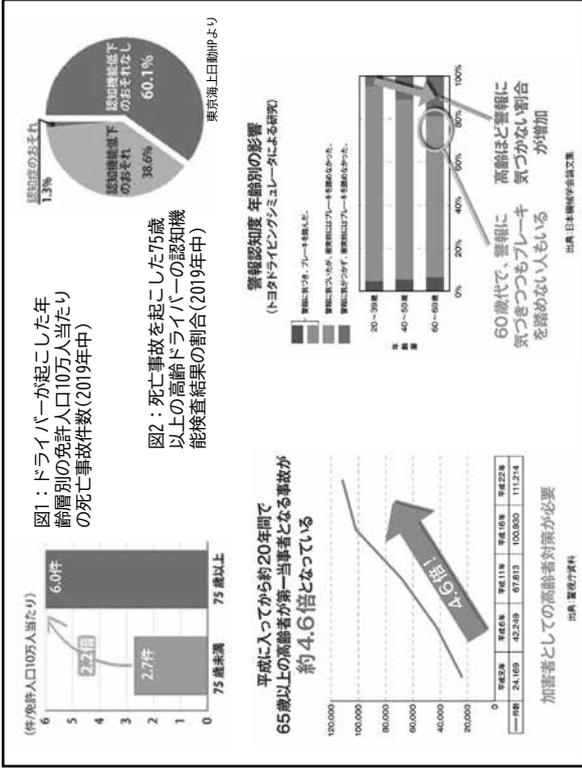


■ 地域公共モビリティの課題 → 道路網：ドライバー不足、利便性確保、乗客率改善

都会	地方地区(地方離散シティ地区)
機能集積 都市中心部(一極化) (多くの人を集める)	商業等集積区(点在) (今は、直接自家用車を乗付ける)
街中エリア 歩行、その他 乗客多数が前提	街中タウン駅エリア(タウン車) 柔軟性
街中駅 鉄道駅	街中路線バス停=街中タウン駅
移動手段 鉄道網(輸送効率UP) バス	道路網(路線バス・乗用車) 柔軟性 無人自動運転車
中継区 鉄道駅(効率よく人を集める)	住区路線バス停=住区タウン駅
移動手段 道路網(路線バス等) 無人 自動運転車	住区タウン駅エリア道路網 (デマンド型バス、支線バス等) 人を集める 努力
住区 郊外	地方離散住区 協同制御 自動運転車

鉄道網	道路網
維持費(バリュウコスト) 線路コスト高	道路コスト低い
運行経費 高い	安い
運転手搬送効率 多量搬送	少量搬送 → 無人化
輸送客 輸送客 多人数が必要	少数でも…柔軟性



## 自動運転での協調制御とは？

### A. 車と周辺空間との協調制御・オンロードジエ(\*)

1. 周辺空間・データ構造の設計
  - (1) 対象物の空間位置Map
    - ① 精密3DMap等・路車協調, データメンテナンス必要
    - ② 動的相対位置・車車協調, 群制御(含, 隊列走行, CACC等)
    - ③ ダイナミックMap・静的位置への変換
  - (2) 危険要因(リスクポテンシャル)Map
    - ① 潜在的・対象物挙動からの推定
    - ② 潜在的・対象物挙動ゆらぎの可能性からの推定(含, ヒヤリハットデータ集積)
2. 協調制御・ストリーム推論(最適化問題)
  - (1) リアルタイム軌道補正
  - ① 衝突回避予測システム
  - ② 先読み運転(Shared Control)・リスクポテンシャル図
- (2) 速度, 路線, ルート制御・飛び出し等の衝突回避マージン考慮
- (3) ハイブリッド・所要時間, 乗り心地, 燃費等を含める最適化

(\*) 発表は明後か; 自動運転用危険予測システムのオンロードジエ導入の方策と課題, The 30th Annual Conference of the Japanese Society for Artificial Intelligence, 2016

### A. 車と周辺空間との協調制御

3. 応答速度・許容遅延時間
    - (1) タイレクト応答・制動距離, 瞬時回避可能ルートに対応
    - (2) 潜在的リスクへの予知応答・人の応答可能速度並みが目標
    - (3) 潜在的リスクへの走行プラン設定
  4. ECUの演算システム
    - (1) 車載オンボード・AI演算可能?
    - (2) 通信系伝達による固定サーバー(含, 遠隔操作, 監視)・通信系の遅延, 5G
    - (3) ハイブリッド型・データ駆動型AIと理論知識型AIの使い分け等
- ### B. 車と人との協調制御・HIMI
1. 遠隔監視, 運行管理システム
    - (1) 1:Nでの無人自動運転車の遠隔監視・運行管理の支援
    - (2) 搭乗者, 乗降者, 車外周辺の人等との協調支援
  2. 有人自動運転システムへの対応
    - (1) 高齢ドライバー等への運転支援システム・低コスト普及型指向も  
→ リスク認知遅れ, 動作移行遅れへの対応
    - (2) リスク回避支援システム(含, ストレス解消, 体調異変対応等)

## いくつかのアプローチ

### かもしれない運転は車(システム)

### 通常運転は人(運転手)

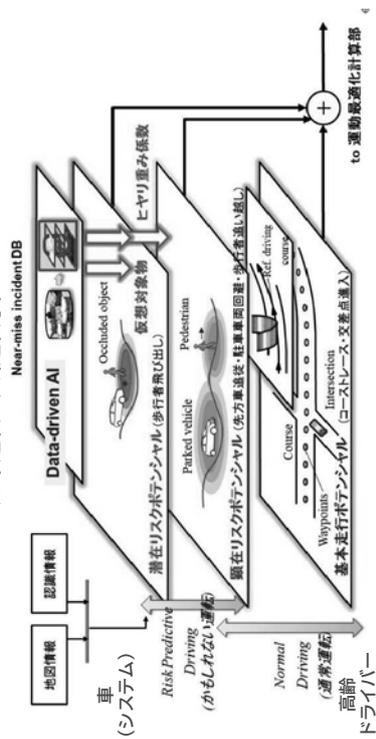


図1 走行リスク予測制御の階層構造

井上秀雄: 「高齢者の自立を支援し安全安心社会を実現する自律運転知能システム」の研究, 最新研究情報, 神奈川工科大学HP

### 人間機械協調制御 (Shared control) リスクポテンシャル最適化理論

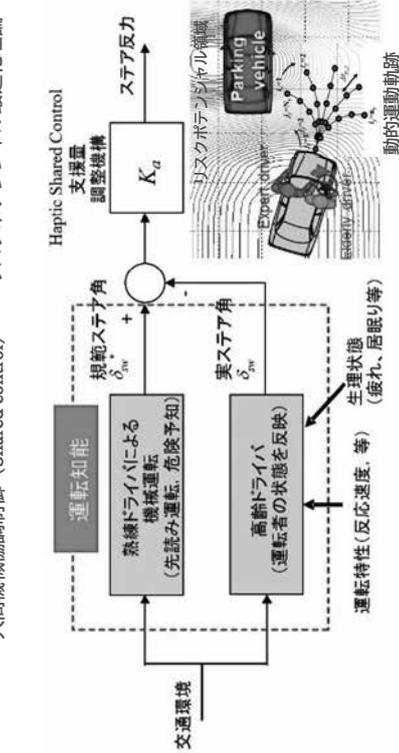
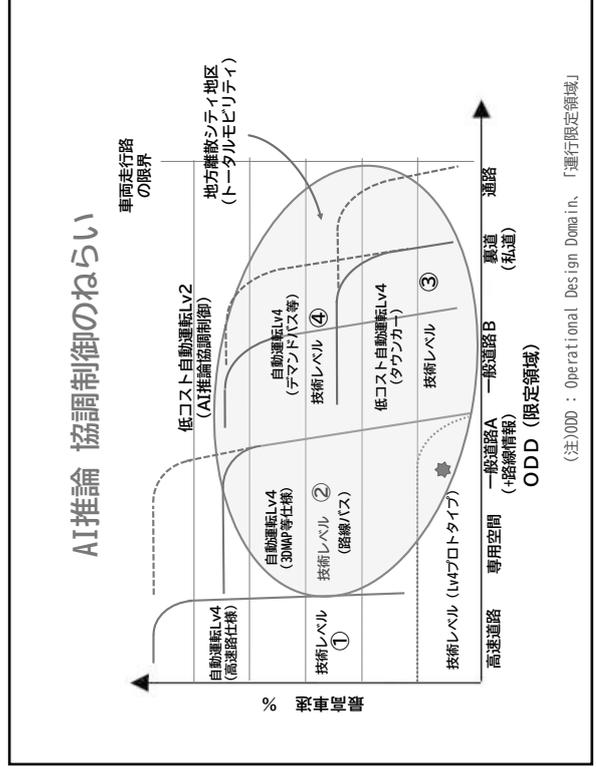
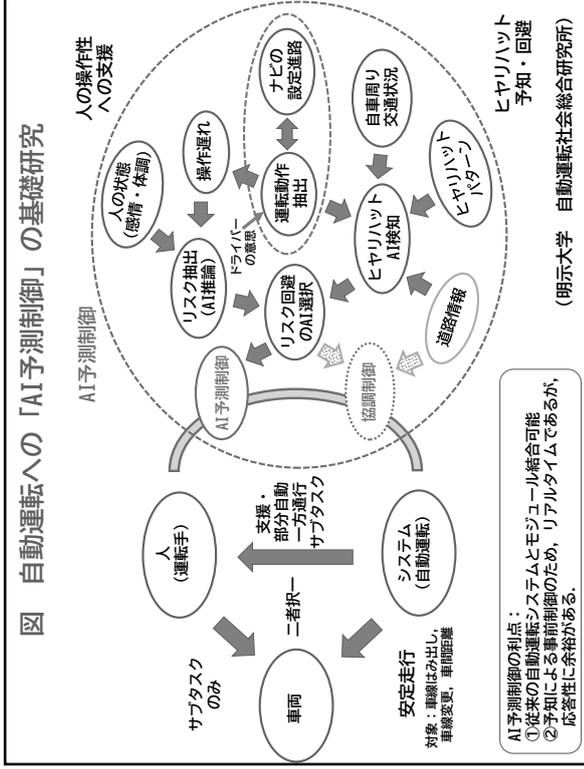
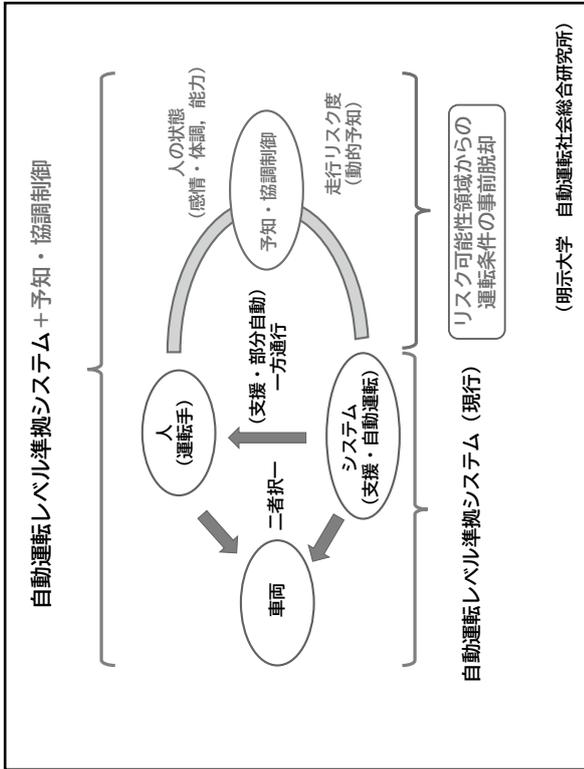


図 熟練者並みの運転知能システム

井上秀雄: 「高齢者の自立を支援し安全安心社会を実現する自律運転知能システム」の研究, 最新研究情報, 神奈川工科大学HP



## 自動運転協調制御の目指すもの

1. (自動運転システム)⇒ドライバー役割の肩代わり⇒(協調制御)
2. 認知・処理 (ドライバー相当) の演算速度：(許容遅延時間)  
(1)ダイレクト応答・制動距離、瞬時回避可能ルートに対応 短い  
(2)顕在的リスクへの予知応答・人の先読み速度並みが目標 ~  
(3)潜在的リスクへの走行プラン設定 長い
  - ▶(演算処理時間+データ通信タイムラグ)とのマッチング重要
  - ▶ODD：許容走行速度に影響
3. 認知対象物の特性の抽出・AI画像処理が必要、演算処理速度も問われる  
(1)移動体の特定：人、動物、自転車、バイク等の混流  
(2)エリアのリスク抽出：道路情報、交差点・ヒヤリハットパターン等の抽出
  - ▶因果関連の見える化・AIへの信頼性、リスクAI規制対応
  - ▶ODD：走行可能な道路環境に影響
4. 目標：ODD(走行速度、道路環境の制約)下でのLv4無人自動運転
  - ▶現状では、実用レベル下限へのチャレンジ⇒制約の緩和へ展開
  - ▶ドライバー不足対応へのニーズが強い
5. 地方離散シテイ地区では、
  - ▶高齢社会：自家用車利用主体⇒交通弱者増加/公共交通の利便性向上
  - ▶低コストの(Lv2とAI推論協調制御)も早期普及⇒支線MaaS対応



# 高齢運転者用移動手段 (運転自動化技術の高齢運転者用車両への活用について)

## Mobility for elderly driver (About the Use of ADS technology for elderly mobility)

白石 恭裕\*<sup>1</sup>,  
白石 恭裕\*<sup>1</sup>, 劉 ジェシカ\*<sup>1</sup>  
Yasuhiro SHIRAISHI\*<sup>1</sup>  
Yasuhiro SHIRAISHI \*<sup>1</sup>, and Jessica RYU \*<sup>1</sup>  
\*<sup>1</sup> (株) グローバル・アクシス Global Axis Co., Ltd.

Use of Automated Driving technology for elderly driver's mobility shows possibility to reduce risk of unwillful acceleration caused by pedal mis operation

**Key Words** : Automated vehicle, Automated driving, Pedal mis operation, Elderly driver, ADAS, ADS

### 1. 緒 言

自動運転の実用化が当初想定されていた時期から後退し、レベル3 システムは 2019 年と発表された実用化時期から遅れている。またいくつかの自動車会社からレベル3 の実用化断念が発表され、現状では一部の自動車会社が 2021 年中の発売を発表するにとどまっている。一方国内では高齢運転者による事故の報道が続き、2019 年に発生した事故の再発防止に期待できる機能について国土交通省、警察庁から自動車会社に打診され、2022 年度の道路交通法改正につながっている。ここでは自動運転システム (ADS) のレベル3 の課題について説明すると共に運転自動化技術を高齢運転者用の車両に活用する例について報告する。

### 2. 運転自動化レベル3 の課題

運転自動化は 0 から 5 までレベル分けされておりレベル3 以上が所謂自動運転で「自動運転システムがすべての動的タスクを実行」と定義されている<sup>(1)</sup>。レベル3 については条件付運転自動化とされ動的運転タスクの作動継続が困難な場合への対応として「応答準備ができている運転者」と定義されている<sup>(1)</sup>。動的運転タスクの概略を図1に、レベル3 での限定領域から利用者の制御再開<sup>(1)</sup>を図2に示す。

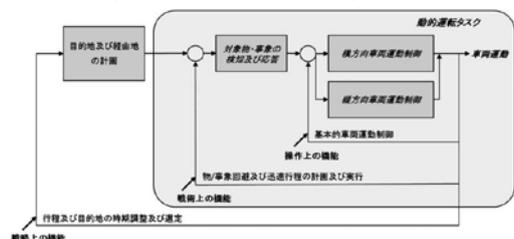


図1 - 運転タスクの概略図

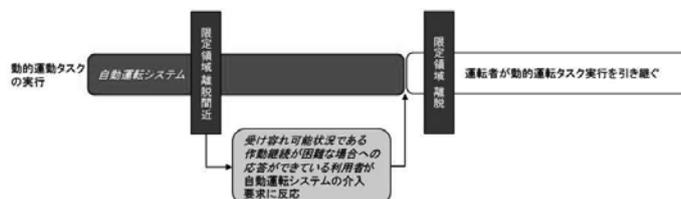


図2 - レベル3 での限定領域から運転者への引継ぎ

レベル3 の課題の一つは運転者が運転タスクを引き継ぐまでの間自動運転システムは必要な作動を継続する必要があるため2重系以上の構成が必要と考えられること。人間工学の観点から動的運転タスクを自動運転システムに任せていた運転者が突然のタスク引継ぎ要求に即応できないとの懸念も示されている。縦・横両方向の車両運動制御に加え対象物・事象の検知と応答をシステムに委ねるが故の課題である。また以上のような技術的課題に加えてレベル3 の車両の要件を規定する道路運送車両法とレベル3 の車両を運転する運転者に関する道路交通法の整備遅れなどを指摘する意見もある。

### 3. 高齢運転者による事故と対応

#### 3・1 高齢運転者による事故

高齢運転者による事故報道は頻発し、経済産業省が普及促進を進めている「安全運転サポート車」に高齢者に推奨する車両として「ペダル踏み間違い急発進抑制装置」を装備したサボカーS が定義されている。しかしながら 2019 年に池袋で発生した事故をきっかけとして発進時のみでなく走行中の速度過多を防止する高齢運転者向け機能と高齢運転者限定免許への採用についての論議が国土交通省、警察庁と主要自動車会社間でなされ、速度リミッターの導入が例示されたが交通流への影響など様々な懸念が示され実用化に至っていない。

#### 3・2 道路交通法の改正

2022 年度施行予定の道交法改正では当初検討されていた高齢運転者限定免許は導入されず、一定の違反・事故歴のある 75 歳以上に対して実車試験による運転技能検査が追加され、不合格者には免許更新を認めないこととなった<sup>(2)(3)</sup>。限定免許については年齢に関係なく任意で、安全運転サポート車のみ運転できるものとなった。

### 4. 高齢運転者対応システム

#### 4・1 縦方向運転自動化技術の活用

アクセルとブレーキの踏み間違いによる意図しない発進や急加速を防ぐ手段として、加速側の制御はシステムが行い運転手は制動側のみ介入可能な機能が考案されている<sup>(4)</sup>。実用的な機能としてレベル 3 の縦方向制御機能とアクセルペダルを発進要求スイッチとしたものとの組み合わせが考えられる。車速と加速度は予め設定された値で制御されるため、アクセルペダルを踏みこんでも急加速は生じない。一方ブレーキペダルは従来機能のまま減速側についてのドライバー介入は自由である。地図情報及び道路標識を読み取ることで決められた最高速度に沿った車速設定とすることが可能である。高齢運転者による走行中のペダル踏み間違いによる急加速と過度な速度超過を防ぐことが期待できる。図 3 にシステム構成例、図 4 にペダル部分の例を表す。

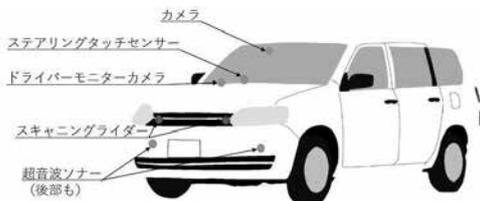


図 3 - 高齢運転者対応システム例



図 4 - ブレーキペダルとアクセルスイッチ例

#### 4・2 高度なレベル 1 の運転自動化システム

上記システムはステアリング支援を行わないため自動化レベルは 1 となる。運転者は操舵タスクを実行するため前方注視が前提となるが、自動化レベル 3 相当の高度な前後方向制御がシステムによって行われるため、過信による前方不注意となる懸念がある。そのためドライバーモニターカメラとステアリングセンサーにより、運転タスクを実行可能な状態のときのみ前後方向制御を制限することが考えられる。

### 5. 結 語

運転自動化技術の縦方向制御機能の活用で高齢運転者のペダル踏み間違い事故のリスク低減が期待できる。

### 文 献

- (1) JASO テクニカルペーパー 自動車用運転自動化システムのレベル分類及び定義 自動車技術会 2018 年制定
- (2) 日本経済新聞 「75 歳以上に実車試験、違反・事故歴で 道交法改正案」 (2020 年 3 月 3 日 8:47)
- (3) 道路交通法の一部を改正する法律案 (閣法第三八号) 内閣委員会
- (4) 公開特許 2019 - 167013 三菱自動車工業(株) 車両の運転支援装置 柴田, 白石他



## 2. 自動運転レベル3の課題



2021/9/7

株式会社 グローバルアウクス

国土交通省HPより

5

## 2. 自動運転レベル3の課題

レベル	名称	特徴	運転者/乗客の役割	システム/ソフトウェアの役割	運転環境/シナリオ	主要な課題
1	レベル1 (ACC)	前方車との追従制御	運転者	追従制御	直線道路	追従制御の精度向上
2	レベル2 (ACC+LKAS)	前方車との追従制御と車線維持	運転者	追従制御と車線維持	直線道路	追従制御の精度向上、車線維持の精度向上
3	レベル3 (ACC+LKAS+SA)	前方車との追従制御、車線維持、周囲車両検知	運転者	追従制御、車線維持、周囲車両検知	直線道路	追従制御の精度向上、車線維持の精度向上、周囲車両検知の精度向上
4	レベル4 (ACC+LKAS+SA+SA-C)	前方車との追従制御、車線維持、周囲車両検知、歩行者検知	運転者	追従制御、車線維持、周囲車両検知、歩行者検知	直線道路	追従制御の精度向上、車線維持の精度向上、周囲車両検知の精度向上、歩行者検知の精度向上
5	レベル5 (ACC+LKAS+SA+SA-C+SA-F)	前方車との追従制御、車線維持、周囲車両検知、歩行者検知、横断歩道検知	運転者	追従制御、車線維持、周囲車両検知、歩行者検知、横断歩道検知	直線道路	追従制御の精度向上、車線維持の精度向上、周囲車両検知の精度向上、歩行者検知の精度向上、横断歩道検知の精度向上

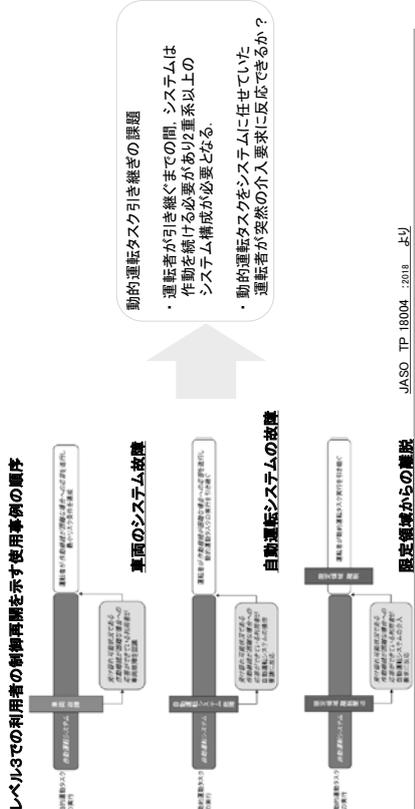
2021/9/7

株式会社 グローバルアウクス

JASO TP 18004 : 2018 より

6

## 2. 自動運転レベル3の課題



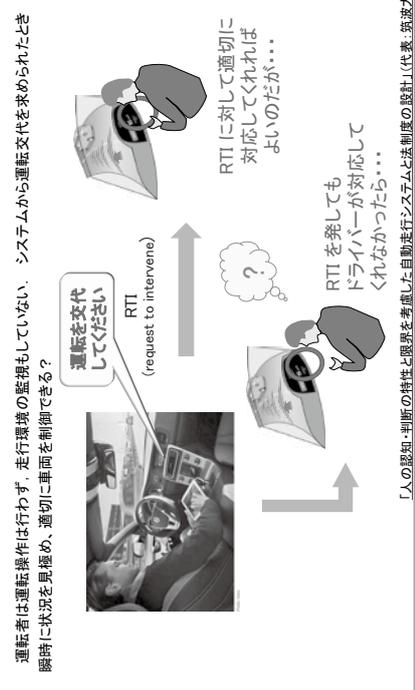
2021/9/7

株式会社 グローバルアウクス

JASO TP 18004 : 2018 より

7

## 2. 自動運転レベル3の課題



2021/9/7

株式会社 グローバルアウクス

JASO TP 18004 : 2018 より

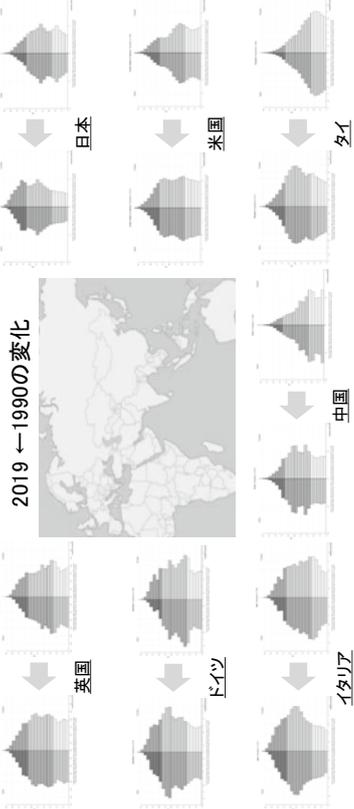
8



### 3. 世界的に進む高齢化

人口構成の逆転現象が顕著となり高齢者ドライバーの増加傾向は続く

2019 ← 1990の変化



2021/9/7

株式会社 グローバルアフランス

9

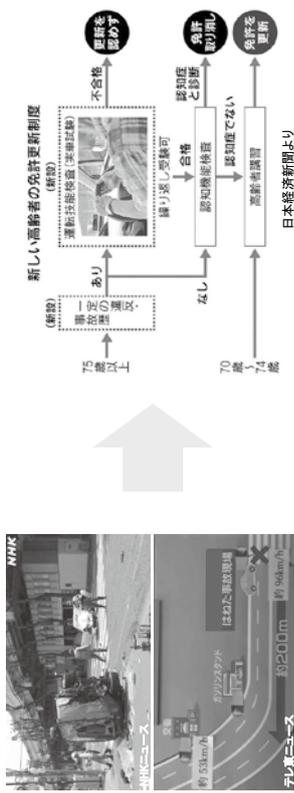


### 4. 高齢運転者による事故と道路交通法の改正

サボカーSのペダル踏み間違い時急発進抑制装置では対応できない事故に対する新たな機能として、スピードリミッター等の後付要請が国土交通省と警察庁から各自動車会社に出された。

結果的に道路交通法の下記改正案が通常国会に提出され、2022年度に施行する方針

- ・違反、事故歴のある75歳以上を対象に運転技能検査(実車試験)を実施し最善に選しなれば免許更新を認めない。
- ・任意制で安全運転サポート車に限り運転できる限定免許を導入。



2021/9/7

株式会社 グローバルアフランス

10

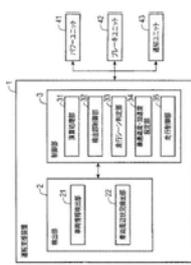


### 5. 高齢運転者対応システム案

特開2019-167013車両の運転支援装置 ; 三菱自動車工業株式会社

【課題】 プレーキベタルとアクセルペダルの踏み間違いをなくすと共に、運転支援をより高度に行う車両の運転支援装置を提供する。

【解決手段】 プレーキベタルがブレーキペダルの操作により行われ、加速制御を行う制御部3を備える。最高速度・加速検出部3.4は、プレーキベタルの解放角速度、車両の車輪と路面との摩擦係数などに基づいて最高速度を決定する。走行初期前部3.5は、最高速度時に基づいて車両のパソコンユニット4.1の最高速度に達した後は、最高速度を維持するようパワートレニット4.1の出力を制御して車両を走行させる。



2021/9/7

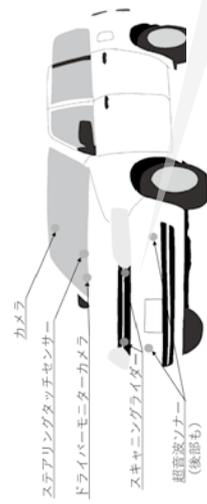
株式会社 グローバルアフランス

11



### 5. 高齢運転者対応システム案

- ・アクセルペダルをゴルフカートの発進スイッチに相当する機能とする。
- ・発進後の車速制御をシステムが行い、道路状況に応じた加速と最高速度で走行する。
- ・ブレーキペダルは従来そのまま減速制のドライバー介入は自由ができる。



ステアリング操作はドライバーが行うため自動化レベルは1. 前後はレベル3相当の高度な制御システムが行いブレーキ操作のみ介入可能。アクセルの発進スイッチ化

2021/9/7

株式会社 グローバルアフランス

12



## 5. 高齢運転者対応システム案

実用化開発の課題と期待

- ・高度な前後方向制御機能による過信の懸念
- ・低μ路面や、災害時の不整路面での走行性能の確保

まとめ

- ・運転自動化技術の縦方向制御機能の活用によりペダル踏み間違い事故のリスク低減が期待できる高齢運転者用の移動手段を提案した
- ・実用化開発を進め高齢運転者限定免許制度の対象システムとしての可能性を検討する

2021/9/7

株式会社 グローバルアウンス

13



## 文献

- ・新型Audi A8のAudi AIトラフィックジャムパイロット Audi Japan Press Center (2017年10月23日)
- ・Audi A8 media info The future of the luxury class
- ・自動運転のレベル分けについて 国土交通省HP
- ・JASOテックニカルペーパー 自動車用運転自動化システムのレベル分類及び定義 自動車技術会 2018年制定
- ・人の認知・判断の特性と限界を考慮した自動走行システムと法制度の設計(代表:筑波大学稲垣敏之、2018年3月2日)
- ・UN World Population Prospects 2019
- ・道路交通法の一部を改正する法律案(罰法第三十八号)内閣委員会
- ・日本経済新聞 「75歳以上に実車試験、違反・事故歴で 道交法改正案」(2020年3月3日 8:47)
- ・公開特許 2019-167013 三菱自動車工業株式会社 車両の運転支援装置 柴田、白石他

2021/9/7

株式会社 グローバルアウンス

14

# ハイブリッド電気自動車の自動運転へのエネルギー最適制御則の導出

## Derivation of Energy Optimal Control Law for Autonomous Driving of Hybrid Electric Vehicles

内田 博志<sup>\*1</sup>, ○正

Hiroshi Uchida<sup>\*1</sup>

<sup>\*1</sup> 福山大学 Fukuyama University

A method of applying energy optimum control (EOC) when the hybrid electric vehicle performs position control has been developed. As a method of deriving an optimal control law suitable for position control, we attempted a method of adding a virtual drive system driven by a position error signal in the model to be controlled, adding its power consumption to the evaluation function and deriving an optimum control law. In the simulation of the preceding vehicle follow-up, good trackability was not obtained in the rule-based control (RBC) of the comparison, but good follow-up results were obtained in the EOC. The engine energy consumption for EOC was only 85.7% of RBC. In the simulation of the target position stopping, energy consumption was effectively suppressed by the function of the efficiency function of the engine and the motor in the EOC. As a result, the EOC consumed about 92% of the RBC's engine energy consumption.

**Key Words** : Hybrid Vehicle, Energy Regeneration, Optimal Control, Energy Flow

### 1. 結 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、エネルギー最適制御理論 (EOC)<sup>(1)-(3)</sup> を、HEV のエネルギーフロー制御に適用している。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<sup>(4) (5)</sup> のように単に位置誤差を考慮したパワー項を加えただけでは安定な位置制御結果は得られない。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. HEV のエネルギーフロー制御

#### 2.1 HEV モデル

図 1 に示す平行 HEV を考える。ホイール、エンジン、モーターの角速度  $\omega_W$ ,  $\omega_E$ ,  $\omega_M$  の関係は、次式で与えられる。 $\gamma_{EW}$  はエンジンからホイールへの減速比の逆数、 $\lambda_{ME}$  はモーターからエンジンへの減速比である。

$$\omega_W = \gamma_{EW} \omega_E$$

$$\omega_M = \lambda_{ME} \omega_E$$

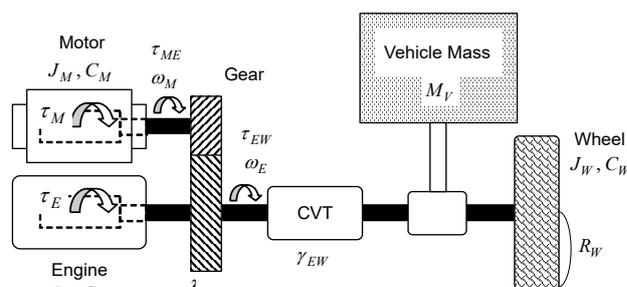


Fig.1 Schematic model of parallel HEV

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.  $\tau_{EW}$  はエンジンがホイールに与えるトルク,  $\tau_{ME}$  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.

$$\frac{\tau_{EW}}{\gamma_{EW}} = J_W \dot{\omega}_W + C_W \omega_W + R_W f_W \quad (1)$$

$$= J_W \gamma_{EW} \dot{\omega}_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \omega_E + R_W f_W$$

$$\tau_E + \lambda_{ME} \tau_{ME} - \tau'_{EW} = J_E \dot{\omega}_E + C_E \omega_E + T_E \quad (2)$$

$$\begin{aligned} \tau_M - \tau_{ME} &= J_M \dot{\omega}_M + C_M \omega_M + T_M \\ &= J_M \lambda_{ME} \dot{\omega}_E + (C_M \lambda_{ME} + J_M \dot{\lambda}_{ME}) \omega_E + T_M \end{aligned} \quad (3)$$

ここで  $\tau'_{EW}$  は  $f_W=0$  のときの  $\tau_{EW}$  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. (1) (2) (3) より,  $\dot{\omega}_E$  と  $\tau_{ME}$  は, それぞれ以下の各式から得られる.

$$\dot{\omega}_E = \frac{\tau_E + \lambda_{ME} \tau_M - \gamma_{EW} R_W f_W - \{C_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \gamma_{EW} + (C_M \lambda_{ME} + J_M \dot{\lambda}_{ME}) \lambda_{ME}\} \omega_E}{J_E + J_W \gamma_{EW}^2 + J_M \lambda_{ME}^2} \quad (4)$$

$$\tau_{ME} = \frac{(J_E + J_W \gamma_{EW}^2) \{ \tau_M - T_M - (C_M \lambda_{ME} + J_M \dot{\lambda}_{ME}) \omega_E \} - J_M \lambda_{ME} \{ \tau_E - T_E - (C_E + C_W \gamma_{EW}^2 + J_W \dot{\gamma}_{EW} \gamma_{EW}) \omega_E \}}{J_E + J_W \gamma_{EW}^2 + J_M \lambda_{ME}^2} \quad (5)$$

$\tau'_{EW}$  を消去することにより, (2) は次式に書き換えられる.

$$\tau_E = (J_E + J_W \gamma_{EW}^2) \dot{\omega}_E + \{C_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \gamma_{EW}\} \omega_E - \lambda_{ME} \tau_{ME} + T_E \quad (6)$$

## 2・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. (6) (3) 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.

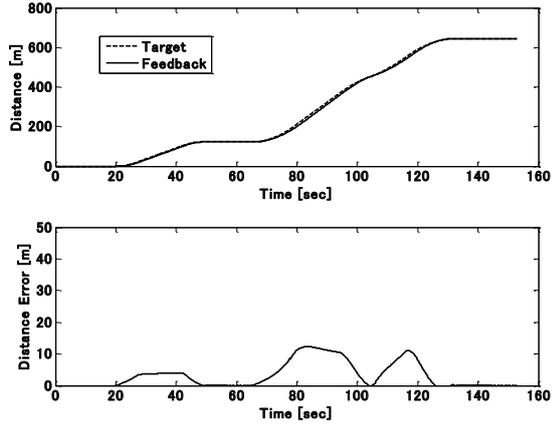
$$\begin{aligned} P_E &= \left\{ (J_E + J_W \gamma_{EW}^2) \dot{\omega}_E + (C_E + C_W \gamma_{EW}^2 + J_W \dot{\gamma}_{EW} \gamma_{EW}) \omega_E \right. \\ &\quad \left. + \gamma_{EW} R_W f_W - \tau_E - \lambda_{ME} \tau_{ME} + T_E \right\} \omega_E \end{aligned} \quad (7)$$

$$P_M = \{J_M \dot{\omega}_M + C_M \omega_M - \tau_M + \tau_{ME} + T_M\} \omega_M \quad (8)$$

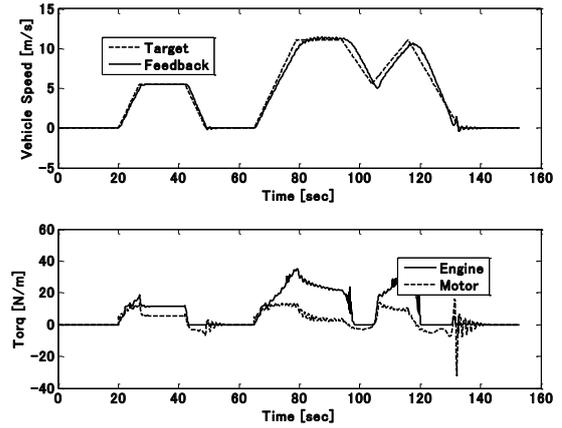
目的関数の被積分関数  $L$  を, 以下のように定義する.  $q_E$ ,  $q_M$  は, それぞれエンジンの燃料消費量とモーターの電力消費量,  $\phi_E$ ,  $\phi_M$  は, それぞれエンジンとモーターの効率関数の逆数,  $\kappa_E$ ,  $\kappa_M$ ,  $r_E$ ,  $r_M$  は重み定数である.

$$L = \kappa_E P_E + \kappa_M P_M + r_E q_E + r_M q_M \quad (1)$$

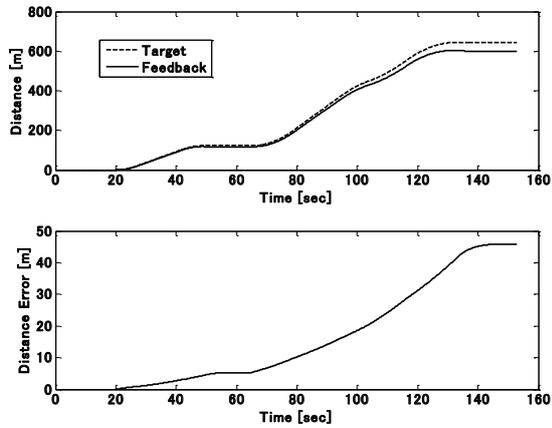
$$q_E = \phi_E \tau_E \omega_E \quad (2)$$



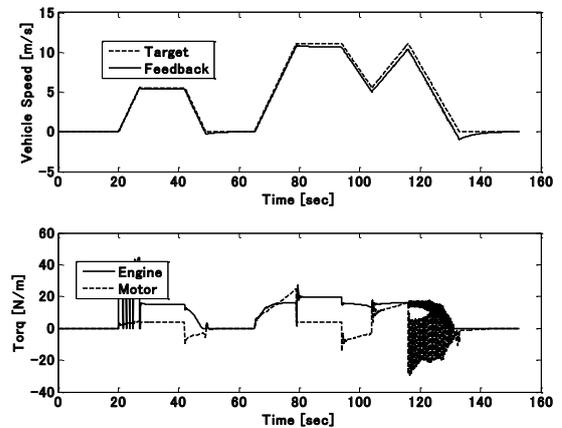
(a) EOC (upper: distance, lower: distance error)



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



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



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

Fig.2 Simulation results (tracking)

Fig.3 Simulation results (tracking)

$$q_M = \phi_M \tau_M \omega_M \quad (3)$$

(1)に、 $\omega_E$ 、 $\omega_M$ に関するオイラーポアソン方程式を適用すると、

$$\begin{aligned} & \frac{\partial L}{\partial \omega_E} - \frac{d}{dt} \frac{\partial L}{\partial \dot{\omega}_E} \\ &= \left\{ \kappa_E - r_E \left( \phi_E + \frac{\partial \phi_E}{\partial \omega_E} \omega_E \right) \right\} \tau_E \\ & \quad - \kappa_E \left[ 2 \{ C_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \gamma_{EW} \} \omega_E + \gamma_{EW} R_W f_W - \lambda_{ME} \tau_{ME} + T_E \right] \\ &= 0 \end{aligned} \quad (4)$$

$$\begin{aligned} & \frac{\partial L}{\partial \omega_M} - \frac{d}{dt} \frac{\partial L}{\partial \dot{\omega}_M} \\ &= \left\{ \kappa_M - r_M \left( \phi_M + \frac{\partial \phi_M}{\partial \omega_M} \omega_M \right) \right\} \tau_M - \kappa_M (2C_M \omega_M + \tau_{ME} + T_M) \\ &= 0 \end{aligned} \quad (5)$$

(4) (5) 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。

$$\tau_E = \frac{2\{C_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \gamma_{EW}\} \omega_E - \lambda_{ME} \tau_{ME} + T_E}{1 - \frac{r_E}{\kappa_E} \left( \phi_E + \frac{\partial \phi_E}{\partial \omega_E} \omega_E \right)} \quad (6)$$

$$\tau_M = \frac{2C_M \omega_M + \tau_{ME} + T_M}{1 - \frac{r_M}{\kappa_M} \left( \phi_M + \frac{\partial \phi_M}{\partial \omega_M} \omega_M \right)} \quad (7)$$

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 P I D 制御の形で与える。

$$T_E = K_{rE} \Delta \theta_E + C_{rE} \Delta \omega_E + J_{rE} \hat{\omega}_E \quad (8)$$

$$T_M = K_{rM} \Delta \theta_M + C_{rM} \Delta \omega_M + J_{rM} \hat{\omega}_M \quad (1)$$

係数  $K_{rE}$ ， $K_{rM}$ ， $C_{rE}$ ， $C_{rM}$  は，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  $C_{rE}$ ， $C_{rM}$  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。

$$C_{rE} = c_{rE0} + c_{rE1} |\Delta \omega_E| \quad (18)$$

$$K_{rE} = k_{rE0} + k_{rE1} |\Delta \theta_E| + k_{rE2} |\Delta \omega_E| \quad (19)$$

### 3. シミュレーション

#### 3.1 シミュレーション方法

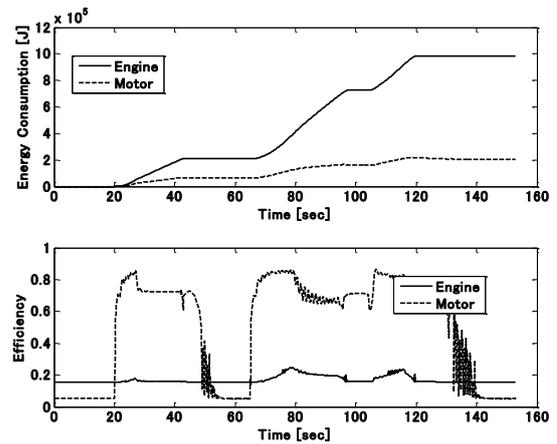
車両に位置の目標値が直接与えられるのは，自動運転による場合が多いと考えられるため，シミュレーションにはドライバーモデルは含めず，位置（走行距離）の目標値に車両が直接追従する形のシミュレーションを行った。制御対象車両にはたらく外乱は，空力抵抗  $f_A$  ところがり抵抗  $f_R$  の和で与えた。

$$f_A = C_d A_f v^2 \quad (4)$$

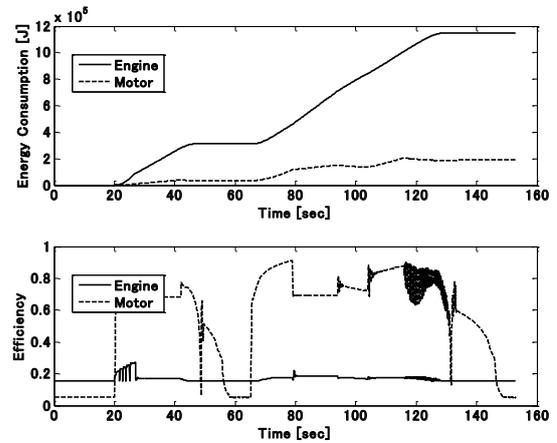
$$f_R = F_R M_V \quad (5)$$

EOC との比較例として，下記の式で求めた  $T_W$  を，ルールベース制御（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。

$$T_E = K_{rE} \Delta \theta_E + C_{rE} \Delta \omega_E + J_{rE} \hat{\omega}_E \quad (22)$$



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



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

Fig.4 Simulation results (tracking)

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

### 3・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. 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 $2 \times 10^5$  [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2から図4にシミュレーション結果を示す. 図2は移動距離と距離の誤差, 図3は車両速度とトルク, 図4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2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發揮できている.

次に図3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見える. 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, 図4に示すように, EOCのエンジンエネルギー消費量はRBCの85.7%で済んだ.

## 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. 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: エネルギー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

# ハイブリッド電気自動車の自動運転への エネルギー最適制御則の導出

Derivation of Energy Optimal Control Law for Autonomous Driving of Hybrid Electric Vehicles

内田 博志 (福山大学)

JSME 2021 年度年次大会ワークショップ  
 WO1100 高度な自動運転を実現するための数理の現状と課題  
 [計算力学部門, 機械工学・システム部門企画]  
 2021年9月7日(火) オンライン開催 (Zoom Meeting)

## はじめに

- 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, 速度バ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。
- そうした位置制御を行う場合のエネルギー最適制御 (EOC) 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。

## エネルギー最適制御

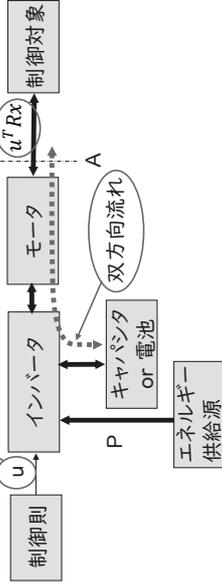
エネルギー一回生最適制御は解が求まらない  
 <現代最適制御理論の枠組みから外れてしまう>

従来の評価関数はこちらに着目

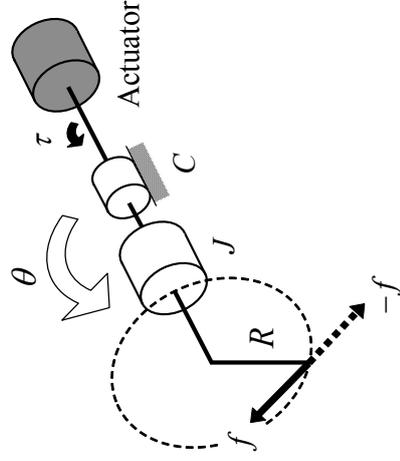
$$J = \int (E_1 + \dots + E_n + u^2) dt$$

パワーの形の評価関数が必要

$$J = \int (P_1 + \dots + P_n + u \cdot r) dt$$



## 仮想回転系



## 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  $\theta$  を実現するためにトルク  $\tau$  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  $\theta$  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  $\tau$  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。

$$T_r = K_r \Delta\theta + C_r \Delta\dot{\omega} + J_r \ddot{\omega}$$

## 制御則

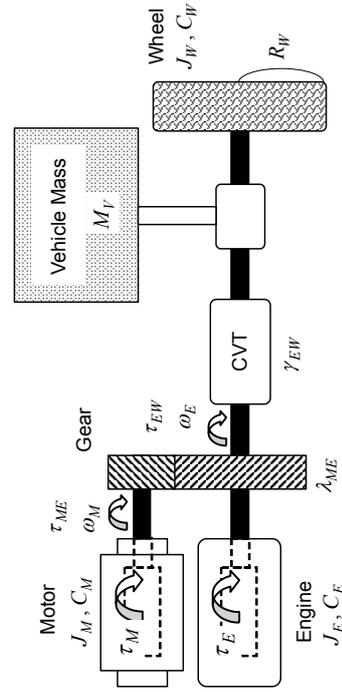
- エンジンとモーターの最適制御則はそれぞれ次式で与えられる。

$$\tau_E = \frac{2\{C_E + (C_W \gamma_{EW} + J_W \dot{\gamma}_{EW}) \gamma_{EW}\} \omega_E - \lambda_{ME} \tau_{ME} + T_E}{1 - \frac{J_E}{K_E} \left( \varphi_E + \frac{\partial \varphi_E}{\partial \omega_E} \right)} \quad (6)$$

$$\tau_M = \frac{2C_M \omega_M + \tau_{ME} + T_M}{1 - \frac{J_M}{K_M} \left( \varphi_M + \frac{\partial \varphi_M}{\partial \omega_M} \right)} \quad (7)$$

7

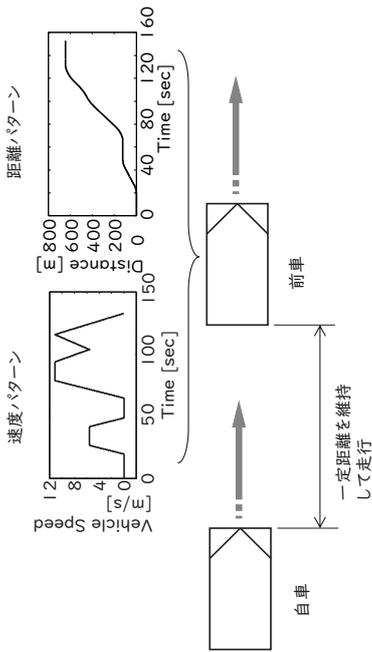
## パラレルHEVの概略モデル



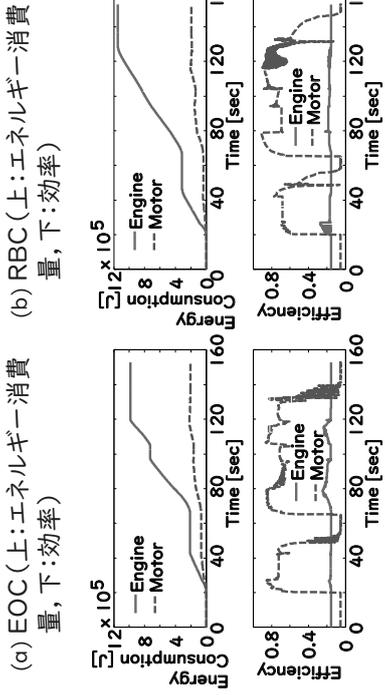
## 前車追従シミュレーション

- 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  $2 \times 10^5$  [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。

## 前車追従シミュレーション



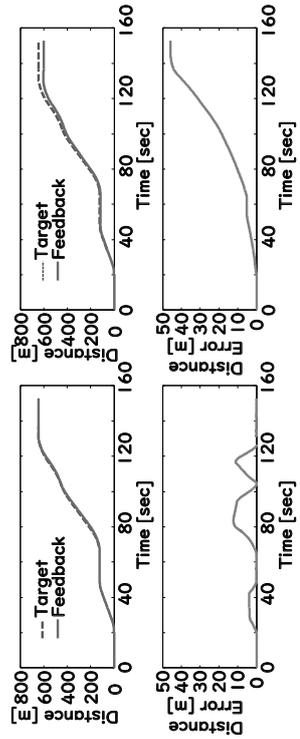
## エネルギー消費量とエネルギー効率 (前車追従シミュレーション)



11

## 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)

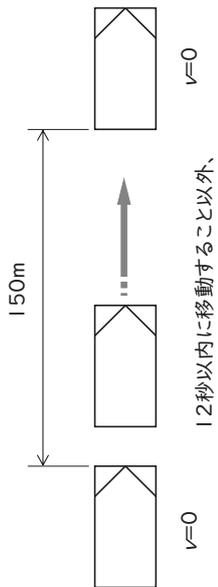


10

## 目標位置停止シミュレーション

- 従来の車両制御では、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できるようにした。

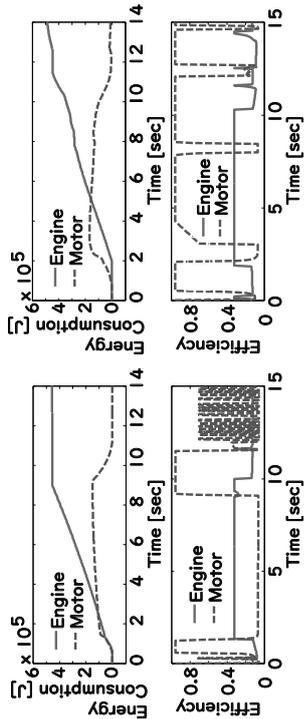
## 目標位置停止シミュレーション



13

## 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)

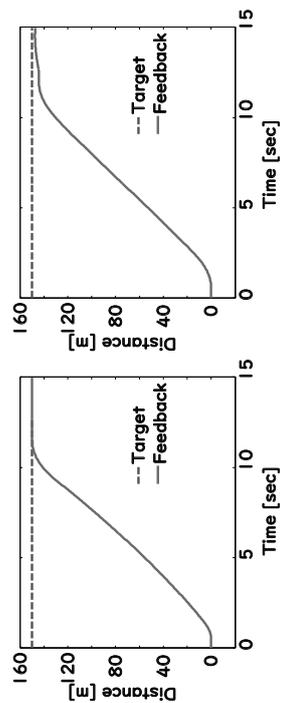
(a) EOC (上: エネルギー消費量, 下: 効率) (b) RBC (上: エネルギー消費量, 下: 効率)



15

## 移動距離 (目標位置停止シミュレーション)

(a) EOC (b) RBC



14

## 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。



# 深層学習を利用したエネルギーベースの モデリング・シミュレーションフレームワーク

## Energy-Based Modeling and Simulation Framework Based on Deep Learning

松原 崇<sup>\*1</sup>, ○谷口 隆晴<sup>\*2</sup>

Takashi MATSUBARA<sup>\*1</sup>, Takaharu YAGUCHI<sup>\*2</sup>

<sup>\*1</sup> 大阪大学 Osaka University

<sup>\*2</sup> 神戸大学 Kobe University

In recent years, neural networks have made remarkable progress in various fields. In particular, a method called Hamiltonian neural network has been developed to construct a model for data that is obtained by observing a phenomenon considered to follow classical mechanics, while preserving the physical properties of the phenomenon. The method has been extended in various ways; however, no discrete-time model that preserves energy conservation and dissipation laws has been proposed. In this study, we propose such a model by combining a method called the discrete gradient method with deep learning. In general, research on deep learning involves not only building models, but also making predictions using the models, which in this case corresponds to physical simulation. Therefore, the proposed framework can be used not only for modeling but also for simulation.

**Key Words** : Energy Conservation, Energy Dissipation, Hamiltonian Neural Network, Discrete Gradient, Deep Learning

### 1. 緒 言

近年、ニューラルネットワークは様々な分野でめざましく発展している。その一つの流れとして、2018年のChenらによるニューラル微分方程式<sup>(1)</sup>の提案をきっかけに、与えられたデータから、そのデータが満たす微分方程式モデルを学習する方法が、数多く、提案されている。特に、ハミルトニアンニューラルネットワーク<sup>(2)</sup>のように、古典力学に従うと考えられるデータに対しては、力学的な性質が成り立つようにモデルを構築する手法も考案されている。ハミルトニアンニューラルネットワークについては、既に様々な形の発展研究や関連研究がなされており、シンプレクティック数値積分法などといった離散力学による手法と連携したものも報告されている<sup>(3)(4)</sup>。しかし、これまでの多くの研究では、ハミルトン系として余接バンドル上のダイナミクス

$$\frac{d}{dt} \begin{pmatrix} q \\ p \end{pmatrix} = S \nabla H, \quad S = \begin{pmatrix} 0 & I \\ -I & 0 \end{pmatrix} \quad (1)$$

のみが対象とされてきた。また、散逸的な系に対する拡張もされているが、ほとんどの場合、(1)に摩擦を加えたものなど、限定的であった。

一方、微分方程式に対する数値解法の研究分野では、エネルギーを保存する系やエネルギーが時間とともに散逸する系に対する特別な数値解法として、構造保存型数値解法と呼ばれる方法が提案されている。これらの数値解法は、系のもつ幾何学的な構造を離散化時に取り入れることで、定性的に良い数値計算結果が得られるように設計されている。このような解法のうち、ハミルトン方程式に対するシンプレクティック数値積分法は、既に様々な形で深層学習モデルに取り入れられているが、エネルギーの保存・散逸性を保つための離散勾配法や離散変分導関数法は利用されていなかった。そこで、本講演では、これらの方法と深層学習を連携することで、エネルギーの保存・散逸則を離散時間でも保つように設計されたモデル<sup>(5)</sup>とそれに関する最近の研究を紹介する。

## 2. 深層学習を利用したエネルギーベースのモデリング・シミュレーションフレームワーク

本研究では,

$$\frac{du}{dt} = G\nabla H \quad (2)$$

という形の方程式でモデル化することができる現象に対し, モデリングおよびシミュレーションを行うためのフレームワークを与える. ここで  $G$  は歪対称または半負定値行列であり,  $H$  はエネルギー関数である. 一般に, この形の方程式は,  $G$  が歪対称行列のときにはエネルギー保存則を, 半負定値行列のときにはエネルギーの散逸則をもつことが知られている. 実際,

$$\frac{dH}{dt} = \nabla H \cdot \frac{du}{dt} = \nabla H \cdot G\nabla H \quad (3)$$

となるが, これは  $G$  が歪対称行列のときには0, 半負定値行列のときには0以下となる. 提案するフレームワークでは, これに対して

$$\frac{u^{(n+1)} - u^{(n)}}{\Delta t} = G\bar{\nabla}H(u^{(n+1)}, u^{(n)}) \quad (4)$$

というモデルを利用する. ここで,  $\bar{\nabla}H$  は離散勾配と呼ばれるベクトルであり, いくつかの性質, 特に

$$H(u^{(n+1)}) - H(u^{(n)}) = \bar{\nabla}H(u^{(n+1)}, u^{(n)}) \cdot (u^{(n+1)} - u^{(n)}) \quad (5)$$

が成り立つように定義される<sup>6)</sup>. 従って, 上記のモデルを利用すると

$$\frac{H(u^{(n+1)}) - H(u^{(n)})}{\Delta t} = \bar{\nabla}H(u^{(n+1)}, u^{(n)}) \cdot \frac{u^{(n+1)} - u^{(n)}}{\Delta t} = \bar{\nabla}H(u^{(n+1)}, u^{(n)}) \cdot G\bar{\nabla}H(u^{(n+1)}, u^{(n)}) \quad (6)$$

という, (3)に対応する式が成り立ち, 離散時間でもエネルギーの保存性・散逸性を成り立たせることができる.

提案するフレームワークでは, (2)に従うと考えられる現象の観測データが一定時間ごとに与えられると仮定し, それに対するモデルを構築し, シミュレーションを行う. モデル(4)のうち, 特にエネルギー関数  $H$  が未知であるが, これは多層パーセプトロン  $H_{nn}$  でモデル化する. 簡単のため,  $G$  は既知であると仮定するが, データから推定することも可能である.

多層パーセプトロンで与えられたエネルギー関数  $H$  に対する離散勾配は, 自動離散微分<sup>6)</sup>というアルゴリズムで導出する. 自動離散微分は, 深層学習の学習アルゴリズムの中で利用されている自動微分の離散版である. ここでは, そのアイデアについて簡単に説明する. 多層パーセプトロンなど, 多くの深層学習モデルは, 活性化関数と呼ばれる非線形関数とアフィン変換の合成で表される. そこで, エネルギー関数が

$$H_{nn}(u) = f(au + b) \quad (7)$$

のように表されていたと仮定する. ただし, 簡単のため,  $u$  は実数であるとする. ここで, 2つの状態  $u, v$  に対して,  $w = au + b, z = av + b$  とおくと

$$H_{nn}(u) - H_{nn}(v) = f(w) - f(z) = \frac{f(w) - f(z)}{w - z} (w - z) = \frac{f(w) - f(z)}{w - z} a(u - v) \quad (8)$$

となるため,  $\frac{f(w) - f(z)}{w - z} a$  の部分が離散勾配となる. 実際には,  $u$  はベクトル,  $a$  は行列となり, また, 関数の合成も繰り返し行われるため, 計算はより複雑になるが, 基本的には, 上記のアイデアの組み合わせで離散勾配を導出することが可能である. なお, 自動微分は深層学習では誤差逆伝播法として知られているが, 上記の計算のう

ち、 $\frac{f(w)-f(z)}{w-z}a$ の部分の計算は $\frac{f(w)-f(z)}{w-z}$ と $a$ を順番に掛ける形で行われており、これは深層学習における誤差逆伝播法の計算に対応している。そのため、誤差逆伝播法のアルゴリズムと同様の方法で実装が可能となる。ただし、離散勾配では、通常の誤差逆伝播法とは異なり、ニューラルネットワークの微分ではなくニューラルネットワークの差分を計算する。そのため、事前に2回の関数評価を行い、それに対応する計算グラフの構築が必要となる。

提案するフレームワークでは、このアルゴリズムを深層学習のライブラリである PyTorch と組み合わせることで実装している。一般に深層学習の研究ではモデルを構築するだけでなく、構築したモデルによる予測も行おうが、予測は今回の場合、物理シミュレーションに対応している。つまり、本フレームワークは、モデル化だけでなくシミュレーションにも利用することができる。また、このように深層学習のライ算も可能となる。加えて、自動微分のアルゴリズムは深層学習モデルに限らず、一般の関数に対しても適用可能である。そのため、あらかじめエネルギー関数が分かっている場合には、エネルギー関数を記述するだけで、GPU を搭載した計算機上で、エネルギーの保存・散逸性を保った高速な物理シミュレーションが可能となる。

以上に加え、最近では、万能近似性のような理論的な性質についても研究が進み始めている。そのような理論的な性質や、実際のモデル化の例などについては、発表当日に紹介する。

### 3. 結 語

本研究では、深層学習と離散勾配法を連携させることで、エネルギー保存・散逸則を保った離散時間モデルを提案した。また、モデルの記述に必要な離散勾配を自動的に求めるための方法についても延べ、実際に、深層学習ライブラリに組み込む形で実装した。これによって、エネルギー保存・散逸則を保ったモデリングおよび物理シミュレーションが GPU を搭載した並列計算機上で容易に行えるようなフレームワークを提案した。

### 謝 辞

本研究は JST CREST (JPMJCR1914)、科研費 (19K20344, 20K11693) の助成を受けた。

### 文 献

- (1) Chen T.Q., Rubanova, Y., Bettencourt, J., and Duvenaud, D., Neural Ordinary Differential Equations, *Advances in Neural Information Processing Systems*, Vol. 31, (2018), pp. 6571-6583.
- (2) Greydanus, S., Dzamba, M., and Yosinski, J., Hamiltonian Neural Networks, *Advances in Neural Information Processing Systems*, Vol. 32, (2019), pp. 15353-15363.
- (3) Zhong, Y.D., Dey, B., and Chakraborty, A., Symplectic ODE-Net: Learning Hamiltonian Dynamics with Control, *In 8th International Conference on Learning Representations (ICLR)*, (2020).
- (4) Zhong, Y.D., Dey, B., and Chakraborty, A., Dissipative SymODEN: Encoding Hamiltonian Dynamics with Dissipation and Control into Deep Learning, *ICLR 2020 Workshop on Integration of Deep Neural Models and Differential Equations (DeepDiffEq)*, (2020).
- (5) Matsubara, T., Ishikawa, A., and Yaguchi, T., Deep Energy-Based Modeling of Discrete-Time Physics, *Advances in Neural Information Processing Systems*, Vol. 33, (2020), pp. 13100-13111.

# 深層学習を利用したエネルギーベースのモデリング・シミュレーションフレームワーク

松原崇 (大阪大学), 谷口隆晴 (神戸大学)

JST CREST 数理的情報活用基盤領域  
幾何学的離散力学を核とする構造保存的システムモデリング・シミュレーション基盤

# 深層エネルギーベース物理モデリング (NeurIPS 2020, top 5%論文)



- エネルギー保存・散逸則を保つシミュレーター
  - 運動法則が不明なときには AI が予測.
  - GPUによる並列計算. プログラミングも簡単.
- 誰でも簡単に物理シミュレーションが可能に!



※ 公開用ウェブページ作成中!

# 対象とする現象

多くの物理現象は「エネルギー」で記述可能!

$$du/dt = \nabla H(u)$$

## エネルギー保存則をもつ系

$G$ : 歪対称 ( $G^T = -G$ )  
 $dH/dt = \nabla H^T G \nabla H = 0$

$$\text{ODEs } u = (q, p)$$

ハミルトン力学  
 $S = \begin{pmatrix} 0 & I \\ I & 0 \end{pmatrix}$

例. 分子動力学  
天体運動

$$\text{PDEs } u = (u_1, \dots, u_n)$$

ハミルトン偏微分方程式

$$D = \frac{1}{2\Delta x} \begin{pmatrix} 0 & 1 & 0 & \dots & -1 \\ -1 & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ 1 & 0 & -1 & \dots & 0 \end{pmatrix}$$

例. 非線形波動  
浅水波, 電磁場

## エネルギー散逸則をもつ系

$G$ : 半不定値 ( $v^T G v \leq 0, \forall v$ )  
 $dH/dt = \nabla H^T G \nabla H \leq 0$

摩擦などのある系

$$S + R = \begin{pmatrix} 0 & I \\ -I & r \end{pmatrix}, r_k \leq 0$$

例. 振り子  
ロケット

フェーズフィールドモデル

$$D_2 = \frac{1}{\Delta x^2} \begin{pmatrix} 1 & -2 & 1 & \dots & 1 \\ -2 & 1 & -2 & \dots & 1 \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ 1 & -2 & 1 & \dots & -2 \end{pmatrix}$$

例. 相分離現象, 結晶成長  
亀裂進展

# 代表的な研究: ハミルトニアンニューラルネットワーク

ポイント: 「物理法則である」という事前知識を活用!

## ハミルトニアンニューラルネットワーク

(Greydanus et al. NeurIPS2019)

- エネルギー関数 ( $H_{nn}$ ) を推定  
することで運動法則を推定
- 物理現象に限定

$$\text{ハミルトン方程式} \\ \frac{du}{dt} = \nabla H_{nn}(u)$$

HNN

物理法則以外は表現不可  
→ 物理法則では性能向上

**定理**  $H_{nn}$  は十分滑らかな活性化関数をもつ多層パーセプトロンとする。相空間がコンパクトであり、真のモデルの右辺がリプシッツ連続ならば、このモデルは万能近似性をもつ。

## 連続時間 vs. 離散時間

ハミルトンニューラルネットワークは連続時間モデル

→ データとして微分値が必要。

また、シミュレーション時にエネルギー保存則などが壊れてしまう！

ハミルトンニューラルネットワーク (Greydanus et al, NeurIPS2019)

エネルギー関数 ( $H$ ) を推定  
することで運動法則を推定

$$\min. \left\| \frac{du}{dt} - \nabla V H_{nn}(u) \right\|_2^2$$

問題1  
データとして、微分値が必要。  
しかし、観測は難しい！

$$\text{ハミルトン方程式} \\ \frac{du}{dt} = \nabla V H_{nn}(u)$$

HNN

シミュレーションで使うときは  
時間離散モデルに変換



シミュレーション  
プログラム  
 $u^{(n+1)} = f(u^{(n)})$

式の形が変わってしまい、  
エネルギー保存性などが  
消えてしまう！

Runge-Kutta法などの  
シミュレーション手法

問題2

エネルギー保存則などが不成立！

## エネルギー保存則などが成り立たないと...

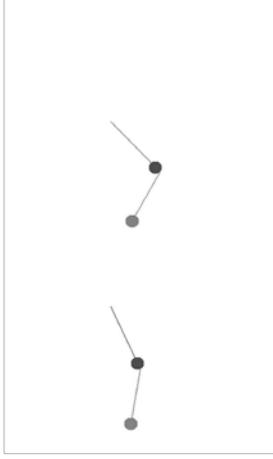
シミュレーションなど、予測結果の  
過小評価・過大評価に直結

→ 信頼できる予測のためには  
物理法則が重要！



振り子のシミュレーション例

左はエネルギー保存則をもたない。  
右はエネルギー保存則をもつ。



## 提案モデル: DGNet (松原-石川-谷口, NeurIPS 2020)

### 離散時間モデル (離散勾配法, Discrete Gradient Method)

エネルギー勾配を利用したモデル → 「エネルギーの離散勾配」によるモデルに拡張

- 離散時間での 厳密なエネルギー保存・散逸性 (数理学分野の技術を応用！)
- 学習に微分データは不要
- モデル=シミュレーションプログラム → Runge-Kutta法などの離散化の影響を排除

### 扱える現象の拡張

ハミルトン力学(運動方程式) → 「エネルギー」で表される統一的な物理モデルに拡張

- エネルギー保存・散逸性をもつ常微分方程式・偏微分方程式
- 数学的には、一般のシンプレクティック・リーマン幾何学の導入

### 新しい自動微分アルゴリズム

自動微分(誤差逆伝播法) → 「自動離散微分」による離散勾配の自動導出

## 「デジタル解析学」: 連鎖律がエネルギー挙動の鍵！

ポイント: 連鎖律の再現

$$\frac{du}{dt} = \nabla H(u) \rightarrow \frac{dH}{dt} = \nabla H \cdot \frac{du}{dt} = \nabla H^T \nabla H \begin{cases} = 0 \\ \leq 0 \end{cases}$$

連鎖律 ← 【重要】離散時間では、通常、不成立！

### 連続時間モデル

$$\frac{du}{dt} = G \nabla H(u)$$

### 離散時間モデル

$$\Delta u / \Delta t = \bar{G} \nabla H(u^{(n+1)}, u^{(n)}) \\ \begin{cases} \Delta u = u^{(n+1)} - u^{(n)} \\ \Delta H = H(u^{(n+1)}) - H(u^{(n)}) \end{cases}$$

連続版の計算の例:  $H(u) = u^3$

$$\frac{dH(u(t))}{dt} = \frac{dH}{du} \cdot \frac{du}{dt} \\ = 3u^2 \cdot \frac{du}{dt}$$

離散版の計算の例:  $H(u) = u^3$

$$H(u(t + \Delta t)) - H(u(t)) = u(t + \Delta t)^3 - u(t)^3 \\ \neq \frac{3u(t)^2 \cdot (u(t + \Delta t) - u(t))}{\nabla H}$$

# 「デジタル解析学」: 連鎖律がエネルギー挙動の鍵!

ポイント: 連鎖律の再現  $\frac{dH}{dt} = \nabla H \cdot \frac{du}{dt} = \nabla H^T G \nabla H$   $\left\{ \begin{array}{l} = 0 \\ \leq 0 \end{array} \right.$

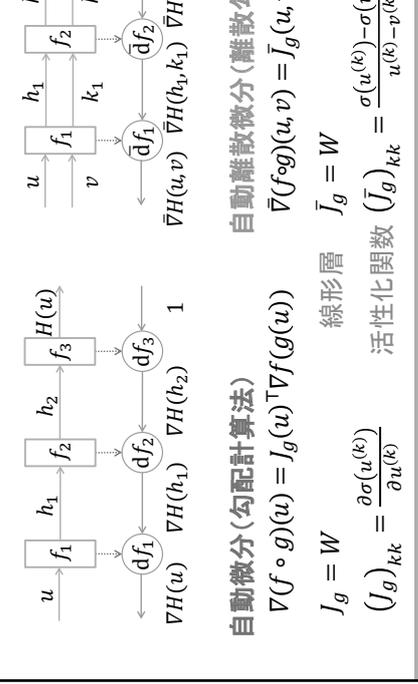
連鎖率  $\leftarrow$  【重要】離散時間では、通常、不成立!

**連続時間モデル**  
 $du/dt = G \nabla H(u)$

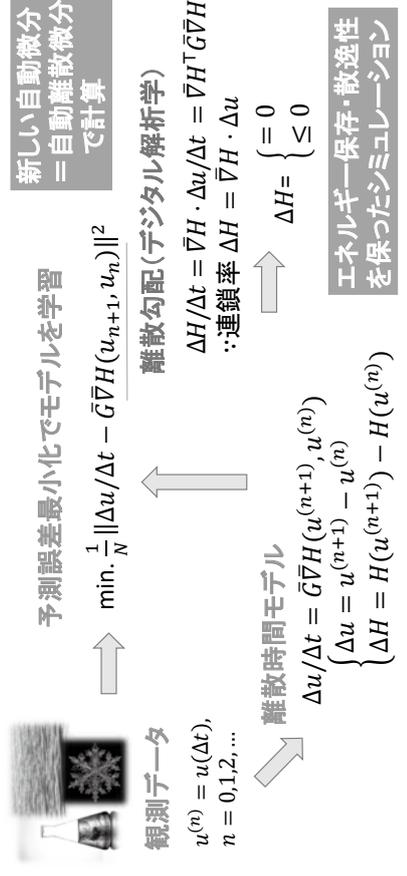
**離散時間モデル**  
 $\Delta u / \Delta t = \bar{G} \nabla H(u^{(n+1)}, u^{(n)})$   
 $\left\{ \begin{array}{l} \Delta u = u^{(n+1)} - u^{(n)} \\ \Delta H = H(u^{(n+1)}) - H(u^{(n)}) \end{array} \right.$

連続版の計算の例:  $H(u) = u^3$  離散版の計算の例:  $H(u) = u^3$   
 $\frac{dH(u(t))}{dt} = \frac{dH}{du} \cdot \frac{du}{dt} = 3u^2 \cdot \frac{du}{dt} = 3u^2 \cdot 3u^2 = 9u^4$   
 $H(u(t + \Delta t)) - H(u(t)) = (u(t + \Delta t))^3 - u(t)^3 = u(t)^3 + 3u(t)^2 \Delta u + 3u(t) \Delta u^2 + \Delta u^3 - u(t)^3 = 3u(t)^2 \Delta u + 3u(t) \Delta u^2 + \Delta u^3$

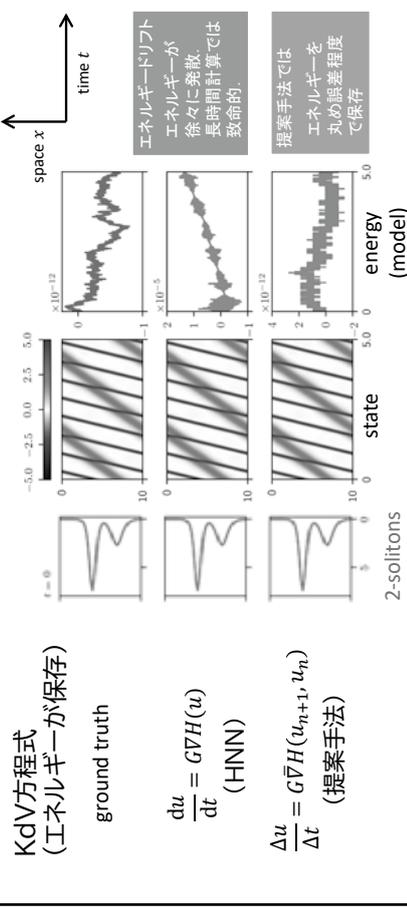
# 高離散勾配はどうやって求めるのか?



# 手法のまとめ



# 実験結果(浅水波)



## 実験結果(相分離)

Cahn-Hilliard方程式  
(エネルギーが減少)

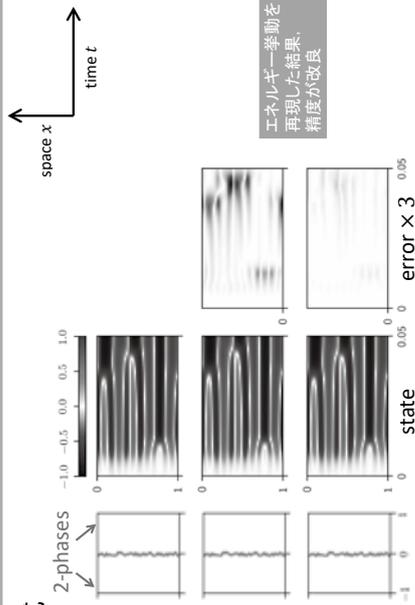
ground truth

$$\frac{du}{dt} = G \nabla H(u)$$

(HNN)

$$\frac{\Delta u}{\Delta t} = G \bar{\nabla} H(u^{(n+1)}, u^{(n)})$$

(提案手法)



エネルギー準動を  
再現した結果、  
精度が改良

## まとめ

### 離散時間モデル(離散勾配法, Discrete Gradient Method)

エネルギー勾配を利用したモデル → 「エネルギーの離散勾配」によるモデルに拡張

- ・ 離散時間での厳密なエネルギー保存・散逸性
- ・ モデル=シミュレーションプログラム → 離散化の影響を排除
- ・ 物理シミュレーションツールとしても有用 (GPUでの並列計算)
- ・ ウェブページ (Google Colab) 準備中



### 扱える現象の拡張

ハミルトン力学(運動方程式)  
→ 「エネルギー」で表される統一的な物理モデルに拡張

### 新しい自動微分アルゴリズム

自動微分(誤差逆伝播法)  
→ 「自動離散微分」による離散勾配の自動導出

現在の取り組み:  
ピアノのモデリング・物理シミュレーション



# 乗員の状況を把握するための因果のわかるニューラルネットワーク

Causality Neural network for Understanding Situation of Occupants<sup>\*2</sup>

○ディアゴ ルイス<sup>\*1</sup>, 安部 博枝<sup>\*1</sup>, 萩原 一郎<sup>\*1</sup>

Luis DIAGO<sup>\*1</sup>, Hiroe ABE<sup>\*1</sup>, Ichiro HAGIWARA<sup>\*1</sup>

<sup>\*1</sup> 明治大学 Meiji University

For autonomous car it is also effective to use machine learning. It is important for the machine learning to be short calculation time and to get smarter with training. And in several cases, it is mandatory to give causality. It is difficult for CNN(Convolutional neural network) which leads the 3<sup>rd</sup> AI boom to get smarter with training because it has long calculation time. HNN(Holographic neural network) is the one that meets these requirements. Here it is compared the original Sutherland's with the modified Hagiwara et al 's and it is shown that the latter is better without overfitting peculiar to neural network. Moreover, some examples are shown.

**Key Words** : Holographic neural network, Overfitting, Moore-Penrose pseudoinverse, Convolutional neural network, Penalty coefficient

## 1. 緒 言

自動走行車は知能者でありそこには、乗員の状況を高精度・高速度な機械学習技術が必要となる。レベル3～5でどのような機械学習技術が必要となるか議論し、HNNはその期待に応えるものであることを示す。

## 2. HNNの基礎理論

### 2.1 元祖 Sutherland の方法

ここで、入力ベクトル  $x = \{x_1, x_2, \dots, x_k\}^T$  と出力ベクトル  $y = \{y_1, y_2, \dots, y_m\}^T$  で表される二つの実ベクトルを仮定する。もし、 $n$  名の教師データがある場合入力行列を  $X$ , 出力行列を  $Y$  とすると、それらは式(1)で表される。

$$\begin{pmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix} Y = \begin{pmatrix} Y_1^T \\ \vdots \\ Y_n^T \end{pmatrix} = \begin{pmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \dots & y_{nm} \end{pmatrix} \quad (1)$$

行列  $X$  と  $Y$  の要素は、写像関数  $f_x$  と  $f_y$  により角度  $\theta_{ai} (a = 1, \dots, n; i = 1, \dots, k)$  と  $\phi_{aj} (a = 1, \dots, n; j = 1, \dots, m)$  に変換できる。

$$\theta_{ai} = f_x(x_{ai}) \quad \phi_{aj} = f_y(y_{aj}) \quad (2)$$

$f_x$  と  $f_y$  は、線型関数やシグモイド関数、逆正接関数等が使用され、次に、指数関数より角度を複素平面上に写像する。

$$s_{ai} = \lambda_{ai} e^{i\theta_{ai}} \quad r_{aj} = \gamma_{aj} e^{i\phi_{aj}} \quad (3)$$

式(3)において、 $i$  は虚数単位である。式(2),(3)の演算を通して、入力  $X$  と出力  $Y$  は複素平面上にそれぞれ刺激  $S$  と応答  $R$  として配置される。

$$S = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1k} \\ s_{21} & s_{22} & \cdots & s_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nk} \end{pmatrix} \quad R = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1m} \\ r_{21} & r_{22} & \cdots & r_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nm} \end{pmatrix} \quad (4)$$

HNN の伝達関数を  $H = [h_1, \dots, h_m]$  とすると、教師データ  $R$  と積  $S \cdot H$  の差の最小化条件から

$$H = (S^* \cdot S)^{-1} \cdot S^* \cdot R \quad (5)$$

が得られる<sup>(1)</sup>

## 2. 2 萩原らの方法

本報の著者の一人萩原らは、式(5)で、 $(S^* S)$ に逆行列が存在しない場合ムーアペンローズ一般化逆行列を用いることも考えられるが、ニューラルネットワークに特有な現象であるオーバーフィッティング現象が生じることがあることを示し、代わりに、次のようなペナルティ関数を定義している。

$$f(h_k) = (r_k - Sh_k)^*(r_k - Sh_k) + \rho_1 h_k^* O h_k + \rho_2 h_k^* h_k \quad (k=1, \dots, m) \quad (6)$$

ここで行列  $O$  は要素がすべて1の正方行列である<sup>(2)</sup>。この関数内の各項の意味は、第1項が出力に対する近似誤差第2項は回帰係数  $h_k$  の平均、第3項はバラツキを表し、それぞれ係数  $\rho_1$ 、 $\rho_2$  により重み付けされている。式(8)に対して  $H$  に何らかの制約がないと一意的に推定できないことから、このような条件を追加した。理論上、第2項が無くても  $H$  は一意的に推定できるが、有るほうが安定的であった。式(6)からペナルティ関数が最小になるように、 $H$  を推定すると次式になる。

$$H_P = (S^* \cdot S + \rho_1 O + \rho_2 I)^{-1} \cdot S^* \cdot R \quad (7)$$

## 3. HNN の適用例

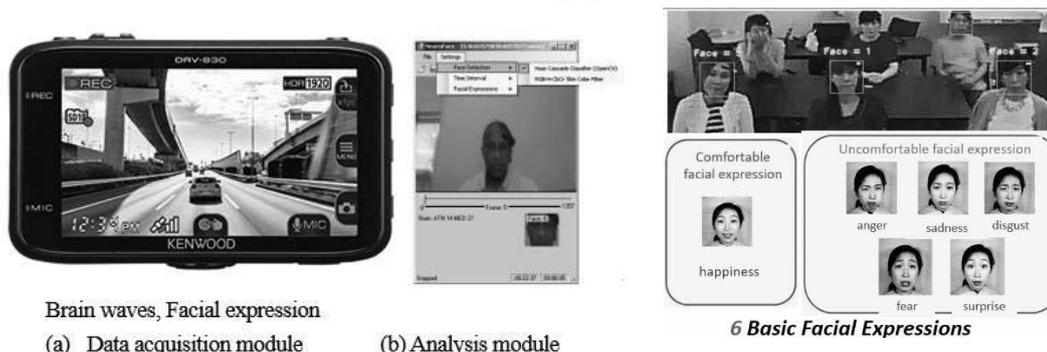


Fig.1 Neuroface Lab Architecture

Fig.2 Comparison between facial expressions extracted in real time and brain waves of plural persons

## 7. 結 語

当日、図1は顔表情で集中度の検索、図2は車室内の乗員の雰囲気を実時間で把握するものであるが詳細は当日説明を行う。

## 文 献

- (1) Sutherland, J. G. The Holographic Model of Memory, Learning and Expression, International Journal of Neural System, Vol.1 (1990), pp.259-267..
- (2) 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 Vol.70 No.689 (2004), pp.54-61.

# 乗員の状況を把握するための 因果の分かるニューラルネットワーク

## Exploring Fuzzy-Quantized Holographic Neural Networks for Driver Monitoring in Conditional Driving Automation

Luis Diago  
(明治大学)



# Overview

## Introduction

- Explainable AI
- Proposed System

## Fuzzy Quantized Holographic Neural Network (FQHNN)

- Previous Works
- FQHNN Architecture
- Extracting Fuzzy Rules

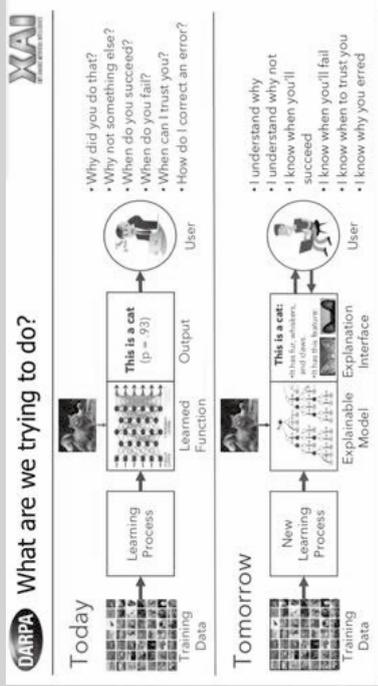
## Conditional Automation (SAE Level 3)

## Experimental Results

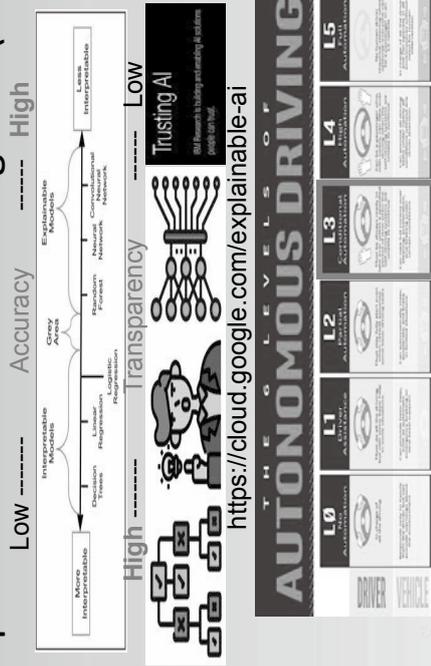
## Conclusion and Future Works



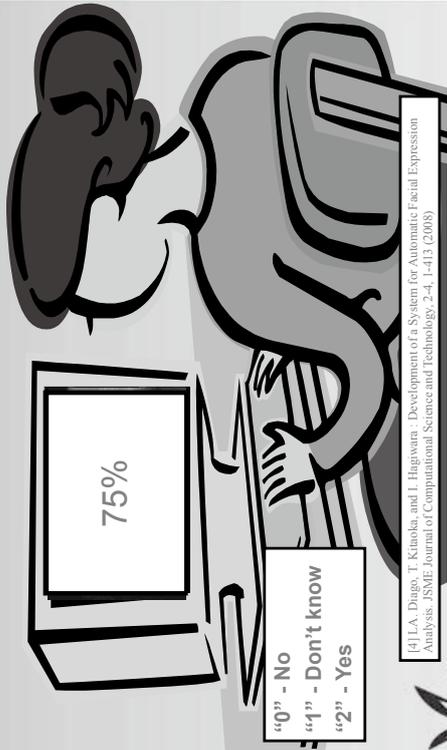
# Explainable Artificial Intelligence (XAI)



# Explainable Artificial Intelligence (XAI)



# Proposed System



[1] I.A. Dugo, T. Kinoshita, and T. Higashimura - Development of a System for Automatic Facial Expression Analysis. JSJAE (Journal of Computational Science and Technology), 2-4, 1-413 (2008)

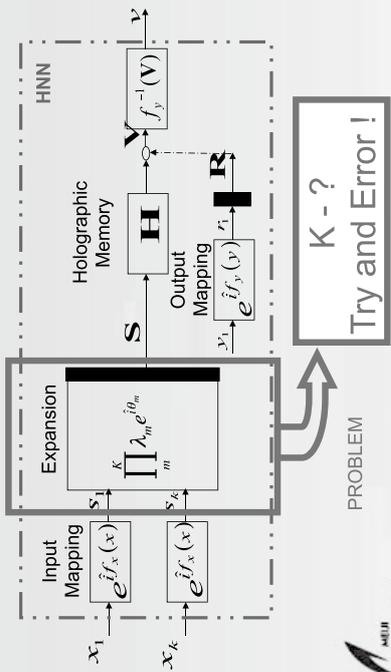
# Overview

- Introduction
- Explainable AI
  - Proposed System
- Fuzzy Quantized Holographic Neural Network (FQHNN)
- Previous Works
  - FQHNN Architecture
  - Extracting Fuzzy Rules

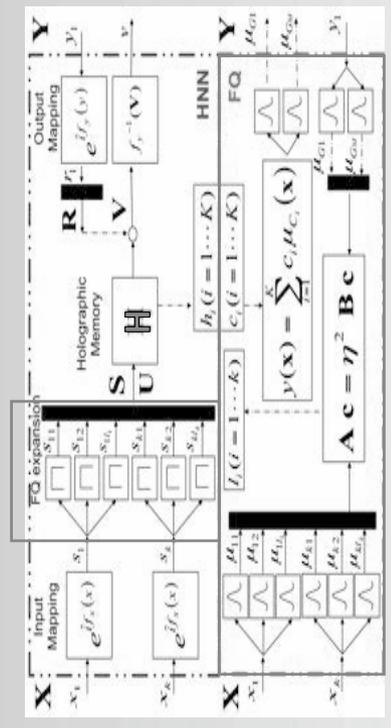
Conditional Automation (SAE Level 3)  
 Experimental Results  
 Conclusion and Future Works

# FQHNN – Previous Works

## Sutherland 1990



# FQHNN - Architecture



[3] I.A. Dugo, T. Kinoshita, and T. Higashimura - Sparse Theory Quantification of Perceptrons of Facial Images based on a Limited Data Set. IEEE Transactions on Neural Networks, 2011

## FQHNN - Extracting Fuzzy Rules

$$H_p = (S^* \cdot S + p_1 0 + p_2 I)^{-1} \cdot S^* \cdot R$$

$R_1$  : if  $x_1$  is  $A_{11}$  and  $x_2$  is  $A_{12}$  and ...  $x_k$  is  $A_{1k}$  then class is  $C$ ;

Steps:

1) Create initial set of rules (Wang & Mendel method).

2) Best rule learning:

$$V_{r,c} = \sum_{p \in C} \epsilon_p^{(r)} \cdot \epsilon_p$$

$$\epsilon_p = \begin{cases} 1, & \text{if } p \text{ is classified correctly,} \\ -1, & \text{otherwise.} \end{cases}$$

3) Keep the  $r$  rules with highest  $V_R$



## Extracting Fuzzy Rules

Table 3 shows a set of 35 rules extracted from the computational models representing the evaluations of each subject.

Rule set A - 21 rules : PCR = 46.95 ± 9.6

No.	IF	THEN	D
1	#16 IS S	#16 IS M	Class-1
2	#16 IS M	#16 IS M	Class-1
3	#16 IS M	#16 IS M	Class-1
4	#16 IS M	#16 IS M	Class-1
5	#16 IS M	#16 IS M	Class-1
6	#16 IS S	#16 IS M	Class-2
7	#16 IS M	#16 IS M	Class-2
8	#16 IS M	#16 IS M	Class-2
9	#16 IS M	#16 IS M	Class-2
10	#16 IS S	#16 IS M	Class-2
11	#16 IS S	#16 IS M	Class-2
12	#16 IS S	#16 IS M	Class-2
13	#16 IS S	#16 IS M	Class-2
14	#16 IS S	#16 IS M	Class-2
15	#16 IS S	#16 IS M	Class-2
16	#16 IS S	#16 IS M	Class-2
17	#16 IS S	#16 IS M	Class-2
18	#16 IS S	#16 IS M	Class-2
19	#16 IS S	#16 IS M	Class-2
20	#16 IS S	#16 IS M	Class-2
21	#16 IS S	#16 IS M	Class-2

According to FQHNN, the classification of Iyashi is mainly based on the upper face:

$x_5$ (11 times),  $x_6$ (8 times) – size of the eyebrows,

$x_{13}$ (7 times) – distance from the right eye to the eyebrow,

$x_{11}$ (4 times) – size of the forehead



## Overview

Introduction

- Explainable AI
- Proposed System

Fuzzy Quantized Holographic Neural Network (FQHNN)

- Previous Works
- FQHNN Architecture
- Extracting Fuzzy Rules

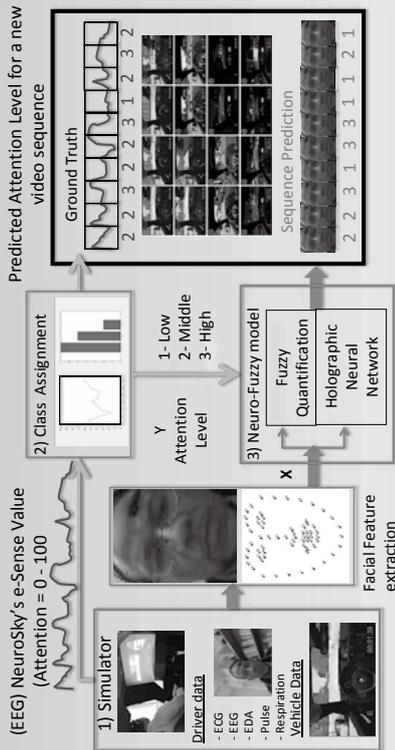
Conditional Automation (SAE Level 3)

Experimental Results

Conclusion and Future Works



## Conditional Automation Approach

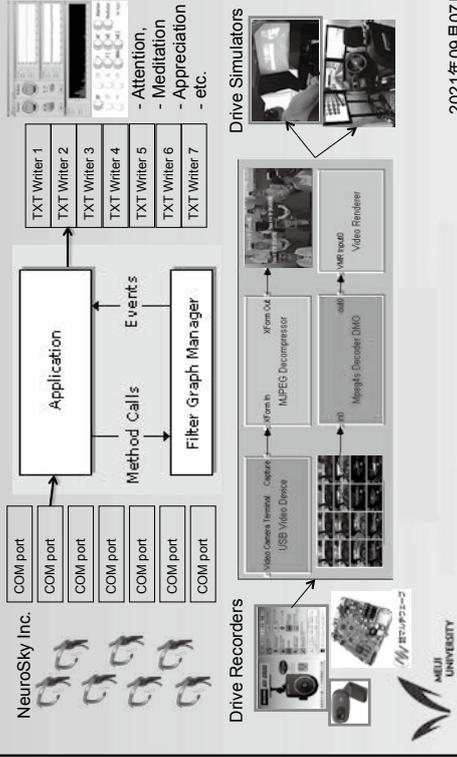


Diego Marquez, L. A., Abe, H., Adachi, K., & Hagiwara, I., (2021). Exploring Fuzzy-Quantized Holographic Neural Networks for Driver Monitoring in Conditional Driving Automation. *Cuban Journal of Digital Transformation*, 2(1), 46-65



# Passengers Emotional States

- Multi face & brain waves architecture -

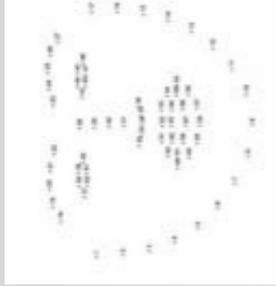


2021年09月07日



# Input - Face Parameters

68 feature points



```

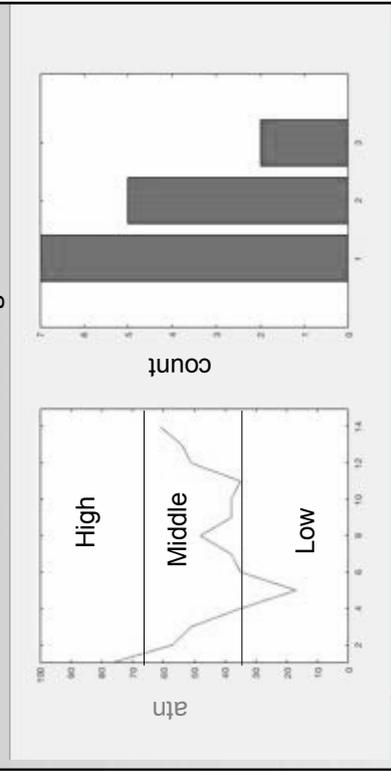
AREAS (A = Area of polygon):
pt(Right eye) = A(37 - 42)
pt(Left eye) = A(43 - 48)
pt(Nose) = A(49 - 60)
pt(Mouth) = A(18 - 27) + A(1, 18, 17, 27) - A(1 - 17)
DISTANCES (D = Euclidean distance):
pt(Vertical face) =  $\frac{1}{2}D(22, 9) + \frac{1}{2}D(23, 9)$ 
pt(Horizontal face) =  $D(17, 1)$ 
pt(Eyes) =  $D(40, 43)$ 
pt(Right eye - eyebrow) =  $\frac{1}{2}D(18, 37) + \frac{1}{2}D(19, 38)$ 
 $+\frac{1}{2}D(21, 39) + \frac{1}{2}D(22, 40)$ 
pt(Left eye - eyebrow) =  $\frac{1}{2}D(23, 43) + \frac{1}{2}D(24, 44)$ 
 $+\frac{1}{2}D(26, 45) + \frac{1}{2}D(27, 46)$ 
pt(Eye mouth) =  $\text{height of triangle}(37, 46, 58)$ 
pt(Vertical mouth) =  $D(52, 58)$ 
pt(Horizontal mouth) =  $D(37, 32)$ 
pt(Right eye - nose) =  $D(46, 36)$ 
pt(Left eye - nose) =  $D(32, 49)$ 
pt(Right eye) =  $D(36, 55)$ 
pt(Left eye) =  $\frac{1}{2}D(3, 32) + \frac{1}{2}D(4, 32)$ 
pt(Right eye) =  $\frac{1}{2}D(14, 36) + \frac{1}{2}D(15, 36) + \frac{1}{2}D(16, 36)$ 
pt(Left eye) =  $\frac{1}{2}D(22, 34) + \frac{1}{2}D(23, 34)$ 
pt(Distance) =  $\frac{1}{2}D(34, 7) + \frac{1}{2}D(34, 8)$ 
 $+\frac{1}{2}D(34, 9) + \frac{1}{2}D(34, 10) + \frac{1}{2}D(34, 11)$ 
    
```

2021年09月07日



# Output - Attention Level

-- Automatic Class Assignment --

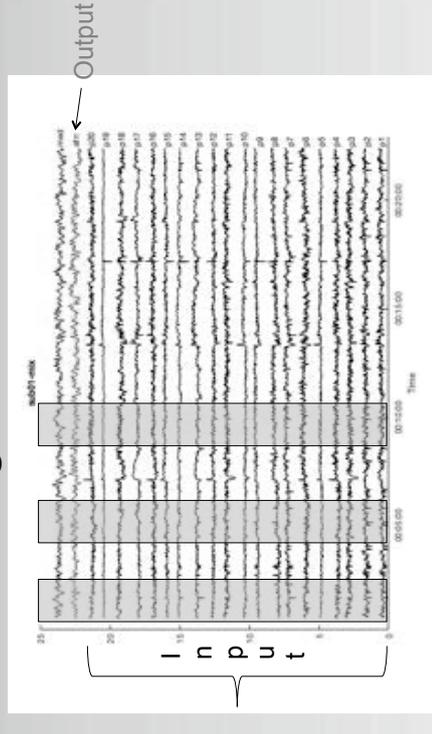


Time (s)  
Class (atn)  
1 - Low 2-Middle 3 - High

2021年09月07日



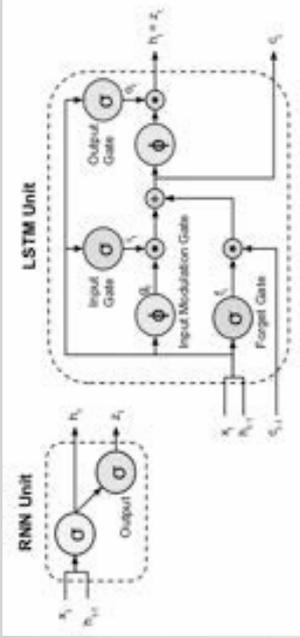
# Learning from Time Series



2021年09月07日



# Long-Short Term Memory (LSTM) (Recurrent Neural Network)



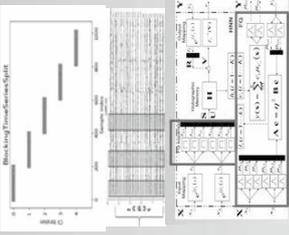
Matlab: MaxEpochs=10, MiniBatchSize=150, InitialLearnRate=0.01  
 SequenceLength=1000, GradientThreshold=1.  
 LSTM Architectures: 20-100-3



# Online Learning: LSTM vs FQHNN

LSTM Matlab R2019: FQHNN Matlab R2019:

MaxEpochs=10,  
 MiniBatchSize=150,  
 InitialLearnRate=0.01  
 SequenceLength=1000,  
 GradientThreshold=1,  
 Architecture: 20-100-3



$f_x: \theta_{li} = \pi/2 + 2\pi(-1)^i/l_i \forall x_{li} \in C_{li} (l = 1 \dots l_i)$   
 $f_y: \phi_{lj} = \pi/2 + 2\pi y_l/m, l_j = 3, m=3,$   
 $\lambda_{0l} = 1, \gamma = 1, \tau = 1, p_l = 1, p_2 = 1$

$$Accuracy: Acc = Pr(a)$$

$$m: \text{Number of classes}$$

$$MC: \text{Confusion matrix}$$

$$N: \text{Number of samples}$$

$$Pr(e): \text{is the hypothetical probability of agreement by chance.}$$

$$Acc = \frac{\sum_{i=1}^m MC_{ii}}{N}$$

$$Kappa = \frac{Pr(a) - Pr(e)}{1 - Pr(e)}$$



# Overview

- Introduction
  - Explainable AI
  - Proposed System
- Fuzzy Quantized Holographic Neural Network (FQHNN)
  - Previous Works
  - FQHNN Architecture
  - Extracting Fuzzy Rules
- Conditional Automation (SAE Level 3)
- Experimental Results
- Conclusion and Future Works



# Experimental Results (1 of 8)

## Simulator (Video)

File Name: Trip-5w-OK.avi  
 File Size: 350 MB (367,362,828 bytes)  
 Downloaded: 2021/09/07  
 Downloaded: 02:24:41



# Experimental Results (2 of 8)



# LSTM vs FQHNN (18 Subjects)

	T(s)	Train			Test		
		Time (s)	Accuracy	Kappa	Time (s)	Accuracy	Kappa
LSTM	5	259.6637726	0.432774432	0.36322364	6.65843087	0.385796055	0.39802896
	10	148.0760425	0.251985815	0.24606494	3.800359647	0.280100843	0.22487315
	15	108.255066	0.491512445	0.397376448	2.420290973	<b>0.497234119</b>	<b>0.399165647</b>
FQHNN	5	78.75893723	0.258251426	0.252303166	2.294702962	0.265866409	0.250277418
	10	83.7132241	0.470176306	0.324880891	1.178297481	0.394258126	0.316752025
	20	<b>73.2305452</b>	<b>0.540206362</b>	<b>0.428842971</b>	<b>1.36288358</b>	<b>0.216726268</b>	<b>0.184514028</b>
FQHNN	5	69.70108797	0.27731119	0.248432975	0.834031237	0.275661727	0.199153852
	10	0.03464906	0.891328997	0.755490242	0.033039927	0.549811604	0.331587513
	15	0.039554114	0.937907076	0.86230921	0.030112153	0.56562203	0.310490304
FQHNN	5	0.031906417	0.070858237	0.159431033	0.018540665	0.201287881	0.271681343
	10	0.038649143	0.932525952	0.848183391	0.029847085	0.271242405	0.271242405
	20	0.026721636	0.071241297	0.160232917	0.018052212	0.247630128	0.271025991
FQHNN	5	0.033309267	0.971719457	<b>0.936368778</b>	<b>0.024062084</b>	0.561332785	0.344279141
	10	0.023798123	0.056298094	0.126670711	0.012910136	0.254800032	0.277773408
	15	0.023798123	0.056298094	0.126670711	0.012910136	0.254800032	0.277773408

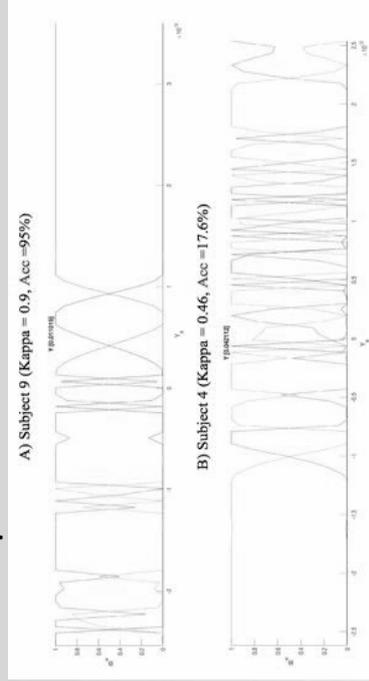


# Subject Dependent Model

Subject	T=5			T=10			T=15			T=20			FQHNN (Best Kappa)		
	Low	Medium	High	Low	Medium	High	Low	Medium	High	Low	Medium	High	Acc	Kappa	T(s)
1	8	46	27	3	27	15	0	22	9	1	15	8	0.733333333	0.4	15
2	42	18	3	25	11	2	19	7	1	13	8	0	0.692307692	0.307692308	15
3	32	35	14	18	20	9	14	15	3	13	9	3	0.347826087	0.318518519	10
4	19	45	26	8	30	11	7	15	12	4	16	6	0.176470588	0.46031746	15
5	21	11	29	13	6	18	8	4	15	7	1	12	0.5	0.111111111	5
6	7	12	13	4	8	11	4	7	8	4	5	6	0	<b>0.555555556</b>	<b>20</b>
7	63	3	4	35	3	3	27	1	2	20	1	2	0.857142857	0.7	5
8	76	3	4	45	1	2	30	1	2	21	1	3	1	1	5
9	90	0	0	49	0	0	34	0	0	26	0	0	<b>0.955555556</b>	0.9	<b>5</b>
10	0	32	53	0	17	30	0	13	19	0	8	17	0.407407407	0.407407407	20
11	46	31	13	29	14	6	18	12	4	15	8	3	0.511111111	0.909090909	5
12	90	0	0	49	0	0	34	0	0	26	0	0	<b>0.955555556</b>	0.9	<b>5</b>
14	12	39	34	5	21	20	2	15	15	1	12	11	<b>0.833333333</b>	<b>0.625</b>	<b>20</b>
15	33	17	40	19	9	21	14	4	16	8	5	13	0.384615385	0.277777778	20
16	34	17	33	18	6	22	14	5	13	9	2	14	0.25	0.407407407	20
17	14	41	29	6	22	18	4	18	10	2	16	6	0.428571429	0.222222222	5
18	22	35	31	10	18	21	6	15	13	4	13	9	0.318181818	0.348148148	5



# Fuzzy Quantification Function for Explanation of the Model



## Overview

### Introduction

- Explainable AI
- Proposed System

### Fuzzy Quantized Holographic Neural Network (FQHNN)

- Previous Works
- FQHNN Architecture
- Extracting Fuzzy Rules

### Conditional Automation (SAE Level 3) Experimental Results

### Conclusion and Future Works



2021年09月07日

## Conclusions (1/2)

- This work proposed an automatic learning model to estimate the observable availability of drivers to taking control in autonomous vehicles
- A data set of multiple physiological variables is collected from drivers of conditionally autonomous vehicles in a simulator that constitutes a valuable database for evaluating different learning models.
- A method was developed for automatic annotation on the preparation for the drivers takeover that allowed training neuro-fuzzy models with an explainable machine learning approach



2021年09月07日

## Conclusions (2/2)

- The model adapts to the characteristics of each conductor and provides a fuzzy quantification function that allows explaining the results of the predictions obtained by the model.
- The proposed model achieves an average prediction percentage of 57% (7% higher than the LSTM models), at the same time that they can be used for online learning due to the fact that their learning is 2000 times faster than LSTM models



2021年09月07日

## FutureWorks

- The prediction percentages obtained by both models are very low. Classification of affective states from the EEG remains a great challenge, as the results barely exceed the accuracy of a random classifier (50-52%) when working with few samples.
- Obtaining a subject-independent model to obtain an ground truth that does not require any calibration for new subjects.
- Use other physiological variables (ECG, EDA, Respiration, Pulse) and select the most important from the model predictions



2021年09月07日

乗員の状況を把握するための  
因果の分かるニューラルネットワーク

Thank you for attention!  
Questions?



# 協調制御利用例

## Cooperative Control Usage Example

○正 安部 博枝<sup>\*1</sup>, ディアゴ ルイス<sup>\*1</sup>, 萩原 一郎<sup>\*1</sup>  
Hiroe ABE<sup>\*1</sup>, Luis DIAGO<sup>\*1</sup>, Ichiro HAGIWARA<sup>\*1</sup>

<sup>\*1</sup> 明治大学 Meiji University

While proceeding with the examination of Level 3, we came to think that the concept of cooperative control is effective for Level 3. In Level 3, when the system cannot stand, the driver receives Request to Intervene(RtI) from the system. This will be only possible if the system itself understands why it requests RtI to the driver and the system can the driver what to do. Before that, it is important to grasp the degree of concentration from the driver's facial expression. To gain cooperative control and thus for Level 3 success, Here it is described the examination of grasping the degree of concentration from facial expressions

**Key Words** : Level 3 autonomous car, Request to intervene, Degree of concentration, Facial expression, Regional revitalization, Driver monitoring system, Brain waves, Face monitoring

### 1. 緒 言

2018年4月に設立された、筆者ら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*）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。我々が進めている活動の一端をここで述べてみたい。

### 2. 協調制御の重要性

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。我々は、自動運転レベル3の実現には、人の認知判断行動の側面から RtI 発生時にドライバーに回避行動に必要とされる集中力があること、システムが何故緊急事態なのかを把握し、ドライバーに理由も含めて何をすべきかの確に指示が出来てはじめて可能になると考えている。さらには、システム、ドライバーのドライバーの集中度に応じて、更にはドライバーの技量に応じてケースバイケースで、システム、ドライバーのど

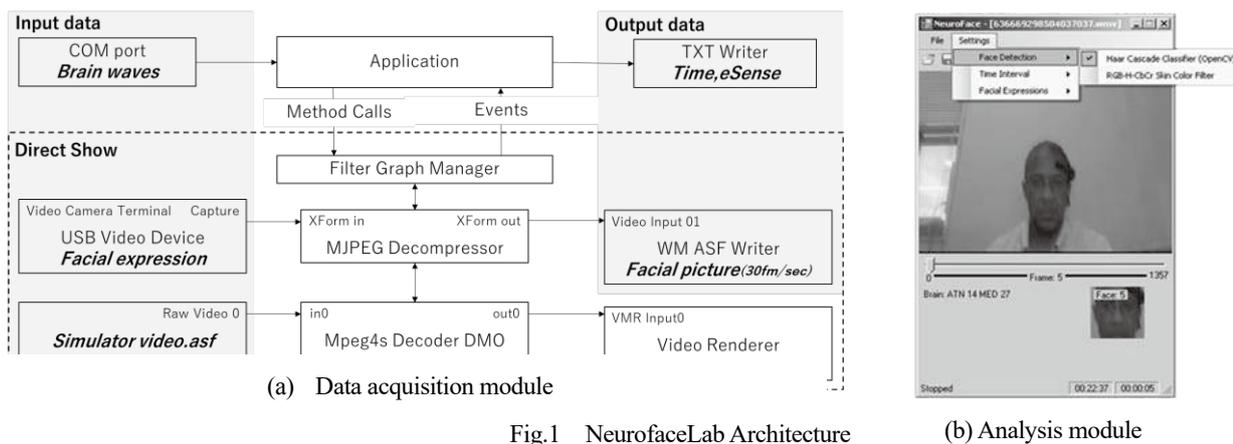


Fig.1 NeurofaceLab Architecture

ちらかが操作をいずれかでなく、どちらかが担うという協調制御で進めるべき、と考えるに至った。このような考えで進めている一例を述べる。

### 3. ドライバーモニタリングシステムの構築

自動運転走行中のドライバーの表情から集中度をリアルタイムで計測し、ドライバーの回避行動能力を判断し、その状況によってはシステムがそのまま継続して操作を行うというものである。そのため、図1に示すドライバーモニタリングシステムの構築した。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PCに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、耳にイヤープ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。YildirimらもeSense値を測定、分析してドライバー警告システムを開発している<sup>(1)</sup>。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。実験で使用した刺激動画は、一般道走行を体感できるものとし、自動運転時に起こりうる注意散漫や疲労、眠気などを起こさせるため、中盤は刺激のない走行シーンとし、歩行者が車道を横切る、隣車線の走行車両と接触しそうになる、といったRtI発生による運転要請が行われると想定したシーンを6シーン挿入し、集中度の変化を計測できるように設計した。開発したアプリケーションでは、実験時の被験者の顔表情を録画した動画と脳波を同期して保存することができるため、オフラインで脳波の値を参照してリアルタイム評価のための、顔表情から集中度を特定する学習ができる。(a)で得た1秒間に30フレームで保存した顔表情画像を(b)のインプットデータとして使用し、全体画像から不必要な背景を除き、顔部のみを抽出している。

### 4. まとめ

顔のモニタリングでは目、鼻、口の配置を手掛かりに顔部を抽出する方式と肌色から抽出するそれぞれ代表的な手法で比較し、成功率が高いことが分かった前者を選択した。

LSTM(Long Term Short Memory)に対するホログラフィックニューラルネットワーク(HNN)の優位性の例、HNNの因果の分かる機械学習技術の協調制御の役割などについて当日述べる。

### 参考文献

- (1) Yildirim, N. and Varol, A., Warning System for Drivers according to Attention and Meditation Status Using Brain Computer Interface, International Journal of Advances in Electronics and Computer Science, Vol.3, No.9 (2016), pp.49-53.

日本機械学会2021年度年次大会  
**W01100 「高度な自動運転を実現するための数理の現状と課題」**  
 タイムスケジュール  
 13:00～ 発表 (10-12分/講演)  
 16:30～ 質疑応答・ディスカッション  
 17:00～ 終了

※ご質問はチャットで難所の質問かを明記して「質問\_山崎\_明治大学」までお願いします。

司会：安部博枝

①自動運転走行車実現のための数理科学 (本ワークショップの狙い)	萩原 一郎	明治大学
②地方創生のための自動走行車	古川 修	明治大学
③自動運転監視制御の目指すもの	岡村 宏	明治大学
④高齢運転者用移動手段 (運転自動化技術の高齢運転者用車両への活用について)	白石 恭裕	㈱グローバルアクセス
⑤ハイブリッド電気自動車の自動運転へのエネルギー最適制御の導出	内田 博志	福山大学
⑥深層学習を用いたエネルギーベースのモデリング・シミュレーションフレームワーク	谷口 隆晴	神戸大学
⑦乗員の状況を把握するための因果の分かるニューラルネットワーク	Diago Luis	明治大学
⑧協調制御利用例	安部 博枝	明治大学

Math Everywhere  
 —モバリングによる数学の展開—

日本機械学会年次大会 特別企画 ワークショップ  
**協調制御利用例**  
 明治大学 安部博枝



私大工学部専攻エンジニアリング専攻  
**数理科学する明治大学**

2

Math Everywhere  
 —モバリングによる数学の展開—

発表内容

1. 背景
2. 自動運転レベル3 実現における課題とアプローチ
3. 実験結果
4. 今後の課題

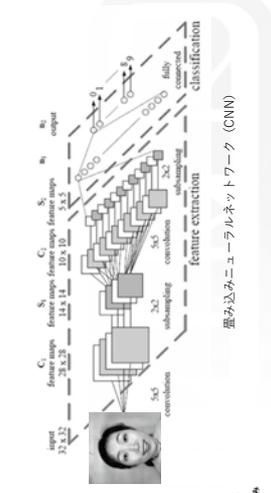
私大工学部専攻エンジニアリング専攻  
**数理科学する明治大学**

3

Math Everywhere  
 —モバリングによる数学の展開—

1. 背景

- AI (機械学習) は深層学習 (Deep Learning) の成果による大幅な進歩
- 従来方法では困難であった領域に拡大



顔の特徴点

多層型ニューラルネットワークによる  
 6 基本表情認識用ニューラルネットワーク

畳み込みニューラルネットワーク (CNN)

私大工学部専攻エンジニアリング専攻  
**数理科学する明治大学**

4

1. 背景 ~感性分野への適用~

顔表情からリアルタイムに集中度や疲労度などの状態を機械学習により予測し、システムへフィードバックする

診断技量への適用      自動運転への適用      介護空間への適用

5

数理解科学する明治大学

1. 背景 ~自動車開発における協調制御~

性能間の関連

6

数理解科学する明治大学

1. 背景 ~自動車開発における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を測るコンセプトの提唱（1996年）

機械はどうやって人間の感情を検知するのか？

自動車自身が人間の感情を読みとる

7

数理解科学する明治大学

2. 自動運転レベル3実現における課題とアプローチ

SAE レベル	SAEにおける要件	SAEにおける定義	ハンド制御の必要性	運行中のモニタリング	運行中のパフォーマンス	システム能力
0	手動	ドライバーが、常時、すべての運転操作を行う。	必要	ドライバー (人間)	ドライバー (人間)	システム能力は、運転モードに依存する。
1	補助	運転システムが進行方向に付いた Lane Keeping Assist (LKA) を提供し、ドライバーが運転操作を行う。	必要	ドライバー (人間)	ドライバー (人間)	いくつかの運転モード
2	部分的な自動化	運転システムが進行方向に付いた Lane Keeping Assist (LKA) と Adaptive Cruise Control (ACC) を提供し、ドライバーが運転操作を行う。	必要	ドライバー (人間)	ドライバー (人間)	いくつかの運転モード
3	条件付き自動化	運転システムが進行方向に付いた Lane Keeping Assist (LKA) と Adaptive Cruise Control (ACC) を提供し、特定の運転モードにおいて自動化された運転操作を行う。	不要	システム	システム	いくつかの運転モード
4	高度な自動化	運転システムが進行方向に付いた Lane Keeping Assist (LKA) と Adaptive Cruise Control (ACC) を提供し、特定の運転モードにおいて自動化された運転操作を行う。	不要	システム	システム	いくつかの運転モード
5	完全自動化	運転システムが進行方向に付いた Lane Keeping Assist (LKA) と Adaptive Cruise Control (ACC) を提供し、特定の運転モードにおいて自動化された運転操作を行う。	不要	システム	システム	すべての運転モード

8

数理解科学する明治大学

## 2. 自動運転レベル3実現における課題とアプローチ

### システムから運転者への権限移譲に関する課題

#### ■人の情報処理過程



#### ■レベル3の処理過程



- ・運転者の注意持続(覚醒度低下の防止)
- ・システムからのRtI(Request to Intervene)のHMI (Human Machine Interface) のデザイン

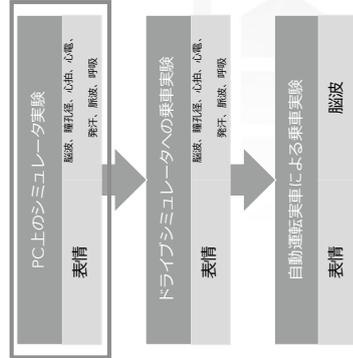
## 2. 自動運転レベル3実現における課題とアプローチ

### <研究目的>

- ▶ 「状況理解」および「状況判断」のプロセスを機械学習でモデリングする
- ▶ 運転者の状態をリアルタイムでモニタリングし、運転者の状態に応じたHMIの最適化を行う

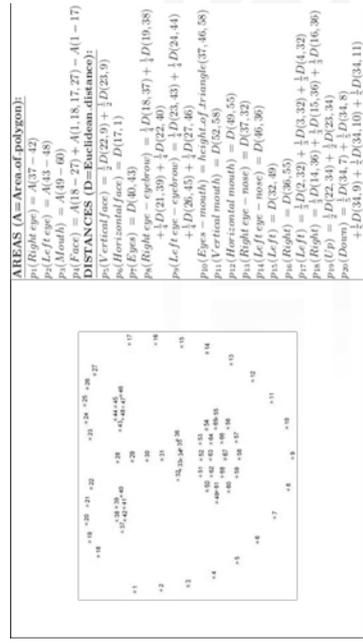


## 3. 実験結果 ～実験デザイン～



## 3. 実験結果 ～顔パラメータ～

64点の顔パラメータ



### 3. 実験結果 ~脳波と表情の同期取得のためのフレームワーク~

Math Everywhere  
—モーションアシストによる脳波の取得—

COM port

Application

Method Calls

Events

Filter Graph Manager

Video Camera Terminal  
Capture  
USB Video Device

Raw Video 0  
Test.asf

Video In  
MPEG Decoder

Yform Out  
MPEG Decoder

Video Input 01  
WM ASF Writer

Video Output  
Video Renderer

Raw Video 0  
Test.asf

Video In  
Mpeg4s Decoder DMO

Video Output  
Video Renderer

TXT Writer

NeurofaceLab Architecture

13

脳波と表情の同期取得のためのフレームワーク

### 3. 実験結果 ~独自の機械学習アルゴリズム~

Math Everywhere  
—モーションアシストによる脳波の取得—

表情

特徴点抽出

脳波

Rough Set Theory (RST) + Holographic Neural Networks (HNN)

$X?$   $Y_1, Y_2, \dots, Y_n$  Quality of Classification (QC)

Holographic Neural Network (HNN)

$D(x, y) = \frac{|[x]_B \cap [y]_B|}{|[x]_B \cup [y]_B|} = HNN(Y, B)$

集中度に関連する要素

感性評価

集中度予測

14

独自の機械学習アルゴリズム

### 3. 実験結果 ~レベル3を想定した運転者の集中度の変化~

Math Everywhere  
—モーションアシストによる脳波の取得—

100

90

80

70

60

50

40

30

20

10

0

顔/フレームータ

集中度

100 95 90 85 80 75 70 65 60 55 50 45 40 35 30 25 20 15 10 5 0

15

レベル3を想定した運転者の集中度の変化

### 3. 実験結果 ~被験者の集中度と顔パラメータの変化量比較~

Math Everywhere  
—モーションアシストによる脳波の取得—

100

90

80

70

60

50

40

30

20

10

0

顔/フレームータ

集中度

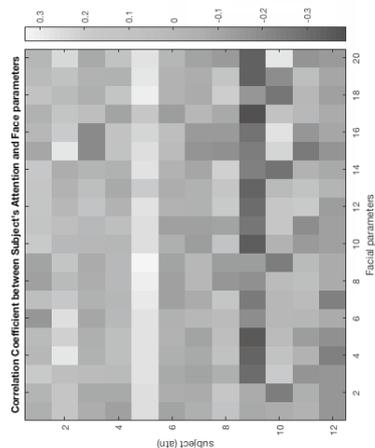
100 95 90 85 80 75 70 65 60 55 50 45 40 35 30 25 20 15 10 5 0

16

被験者の集中度と顔パラメータの変化量比較

### 3. 実験結果

～集中度の高い顔表情と関連の高いパラメータの抽出結果



### 4. 今後の課題

- ・集中度に関連する顔パラメータによる個別モデルの生成
- ・顔表情だけで集中度をリアルタイムに予測できる学習モデルの構築
- ・予測精度の向上



ご清聴ありがとうございました

日本機械学会2021年度年次大会

### W01100 「高度な自動運転を実現するための数理の現状と課題」

タイムスケジュール  
13:00～ 発表 (10-12分 / 講演)

司会：安部博枝

- ① 自動運転走行実現のための数理科学 (本ワークショップの狙い)
- ② 地方創生のための自動走行車
- ③ 自動運転協同制御の目指すもの
- ④ 高級運転者用移動手段 (運転自動化技術の高級運転者用車両への活用について)
- ⑤ ハイブリッド電気自動車の自動運転へのエネルギー最適制御の導出
- ⑥ 深層学習を用いたエネルギーベースのモテリング・シミュレーションフレームワーク
- ⑦ 車員の状況を把握するための因果の分かるニューラルネットワーク
- ⑧ 協同制御利用例

- 初原 一郎 明治大学
- 古川 修 明治大学
- 岡村 宏 明治大学
- 白石 恭裕 ㈱グローバルアクシス
- 内田 博志 福山大学
- 谷口 隆晴 神戸大学
- Diego Luis 明治大学
- 安部 博枝 明治大学

16:30～ 質疑応答・ディスカッション  
17:00～ 終了

※ご質問はチャットで誰宛の質問かを明記して“質問\_山崎\_明治大学”までお願いします。

