



2024年5月24日（金）
第68回 システム制御情報学会 研究発表講演会



交通流現象の観測・モデリングと制御

立命館大学 塩見 康博

自己紹介

• 経歴

- 1981年 生まれは神奈川県 → その後、小学校入学から堺市
- 2003年から研究室配属 卒論テーマ「オートバイを含む交通流の容量解析」
- 2008年9月 京都大学 博士（工学）「車群交通流モデルによる渋滞現象解析」
- 2008年10月～ 2012年3月 京都大学大学院 助教
- 2011年4月～ 2012年3月 デルフト工科大学（オランダ）客員研究員
- 2012年4月～ 立命館大学理工学部 任期制講師
- 2021年11月～ 2022年8月 デルフト工科大学（オランダ）客員研究員
- 2022年4月～ 立命館大学理工学部 教授

• 主な研究テーマ

- 高速道路の渋滞・事故対策
- 交差点設計・信号制御
- 公共交通の計画
- 交通行動分析

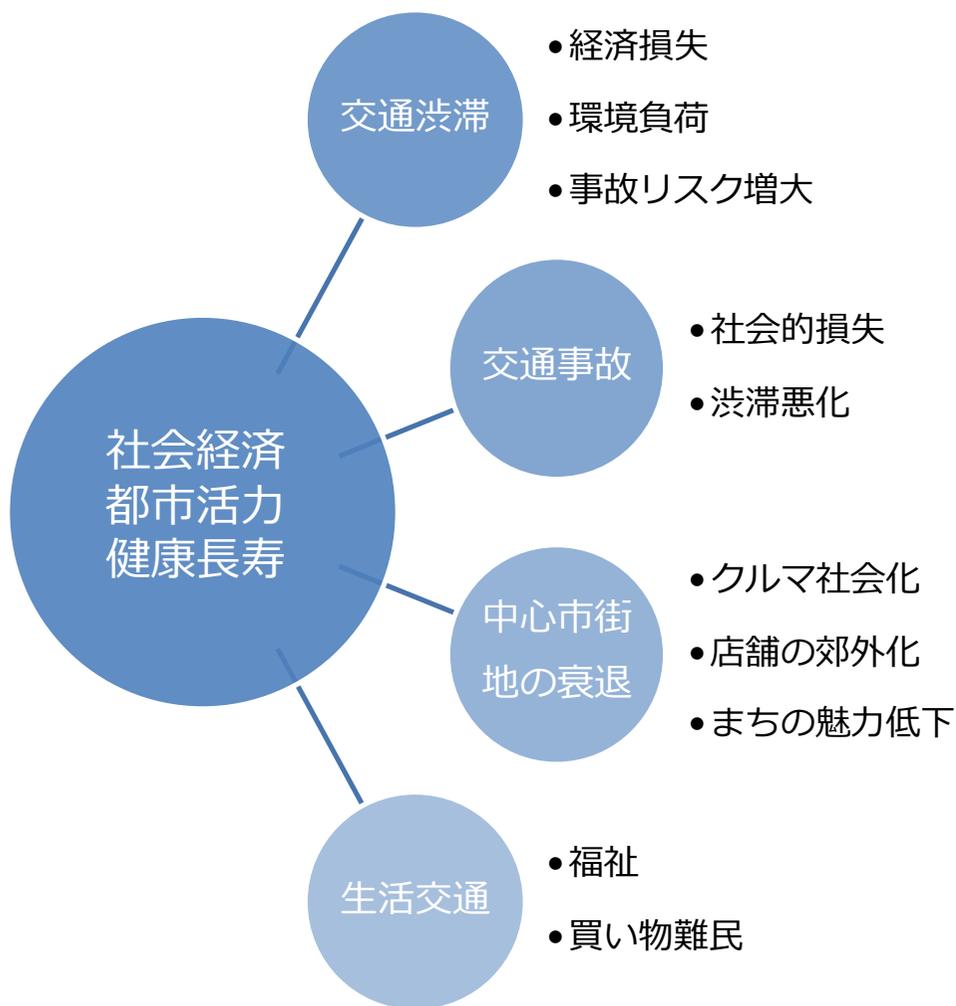


インドネシア・マカッサル

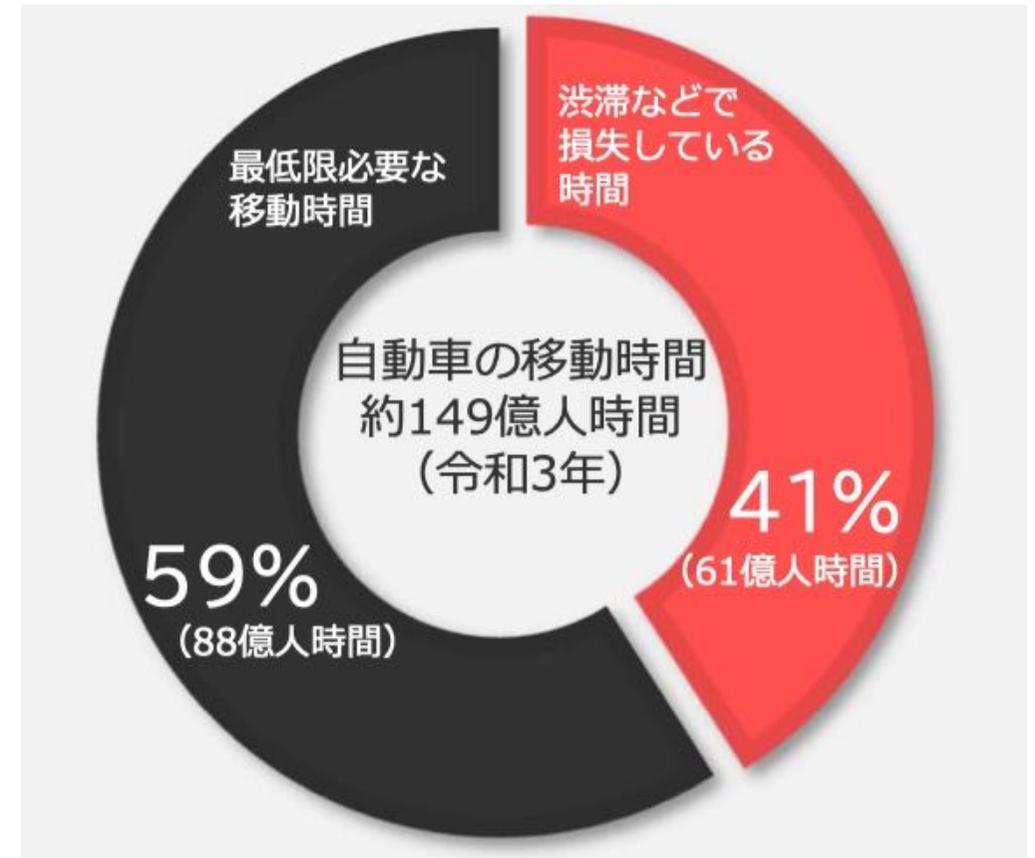


中国自動車道 上り線 宝塚西 T N

交通に関する社会問題



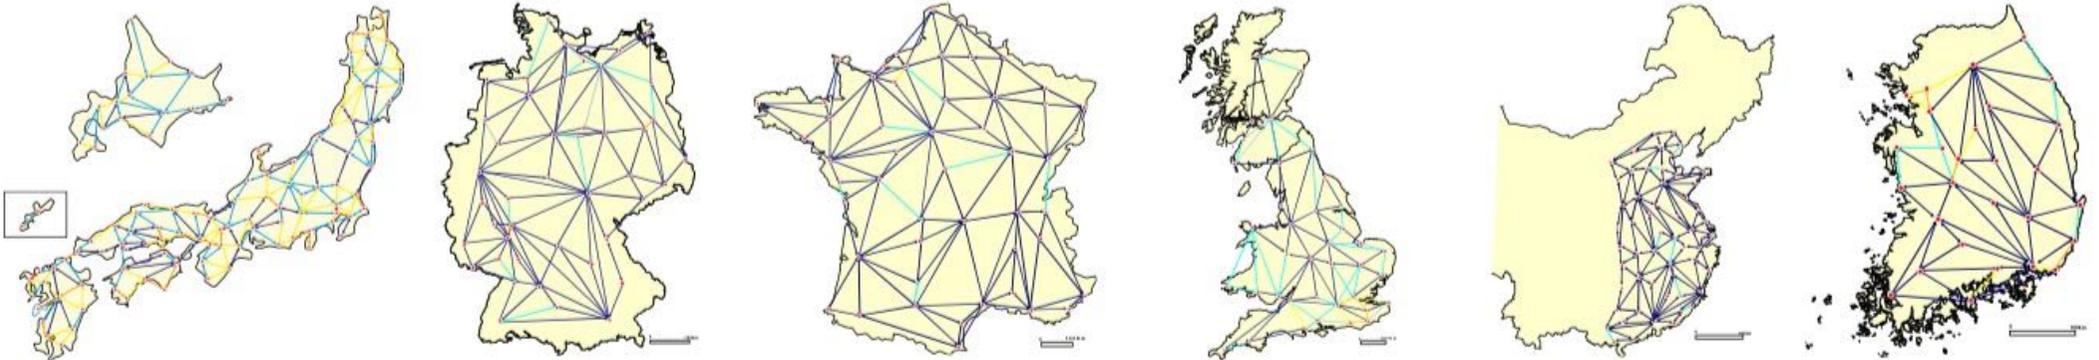
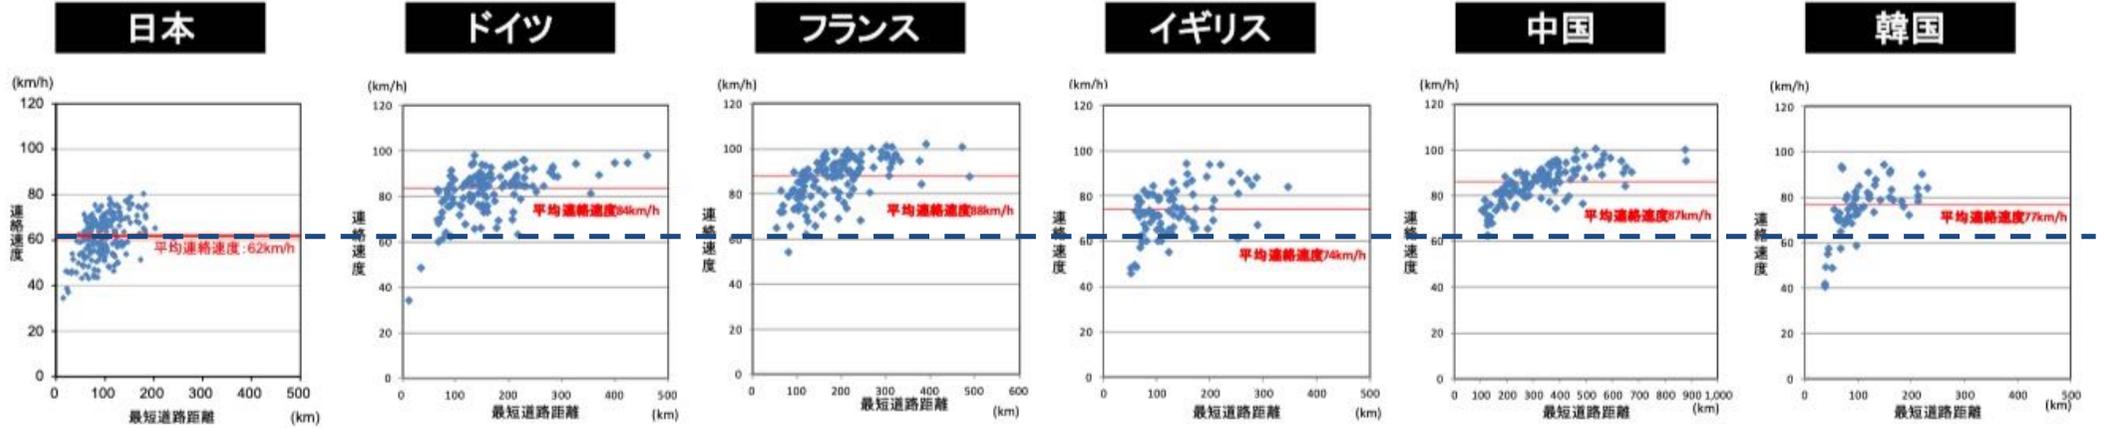
- 日本国内での渋滞による経済損失：
61億人時間
(貨幣価値換算で約19兆円?*)
- 都市間高速道路 (NEXCO3社+本四)
 の経済損失 (2013)
1.9億人時間
貨幣価値換算で約6000億円
- 高速道路における渋滞時の事故リスク：
自由流時の
40~50倍 (大口ら, 2004)
- 渋滞時のCO2排出量 (単位距離あたり)：
自由流時の 1.5~2倍
(国総研, 2010)



* H17は35.1億人時間・11兆円の試算。R5は貨幣換算値は非公表

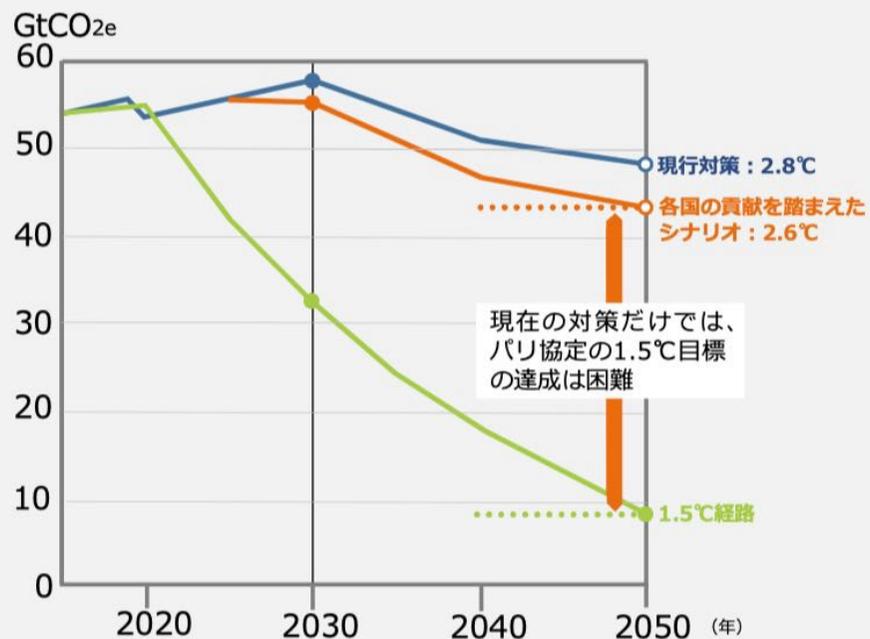
諸外国との比較

- 都市間連絡速度 70km/h以上
- // 60~70km/h
- // 50~60km/h
- // 40~50km/h
- // 40km/h未満



道路からのCO2排出量

シナリオごとの2050年までのGHG排出量推計と排出ギャップ
今世紀の気温上昇

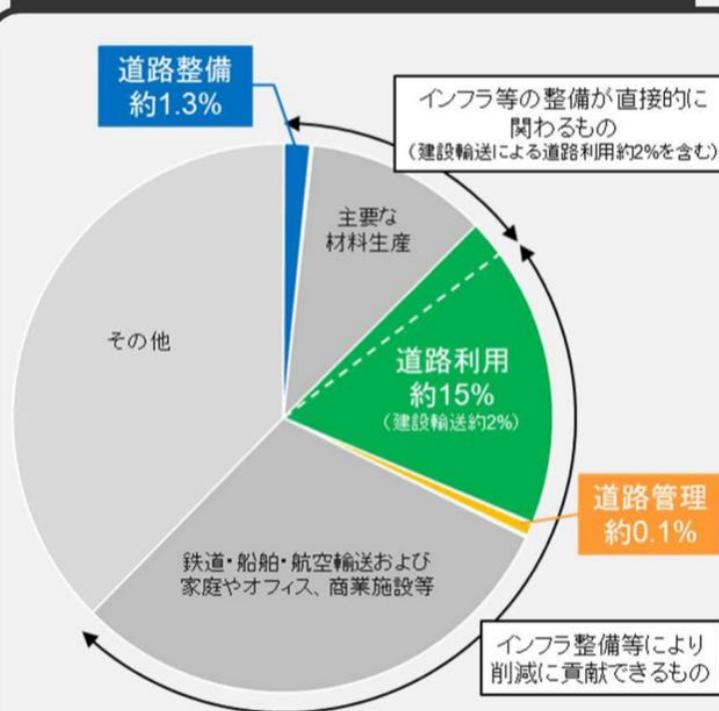


現在の対策だけでは、
パリ協定の1.5°C目標
の達成は困難

UNEP「Emissions Gap Report 2022」を元に国交省作成

“世界は未だパリ協定の目標達成には及ばず、
1.5°Cに向けた信頼性の高い経路に乗っていない”
「Emissions Gap Report 2022」

我が国のCO2排出量の内訳 (2020年度)



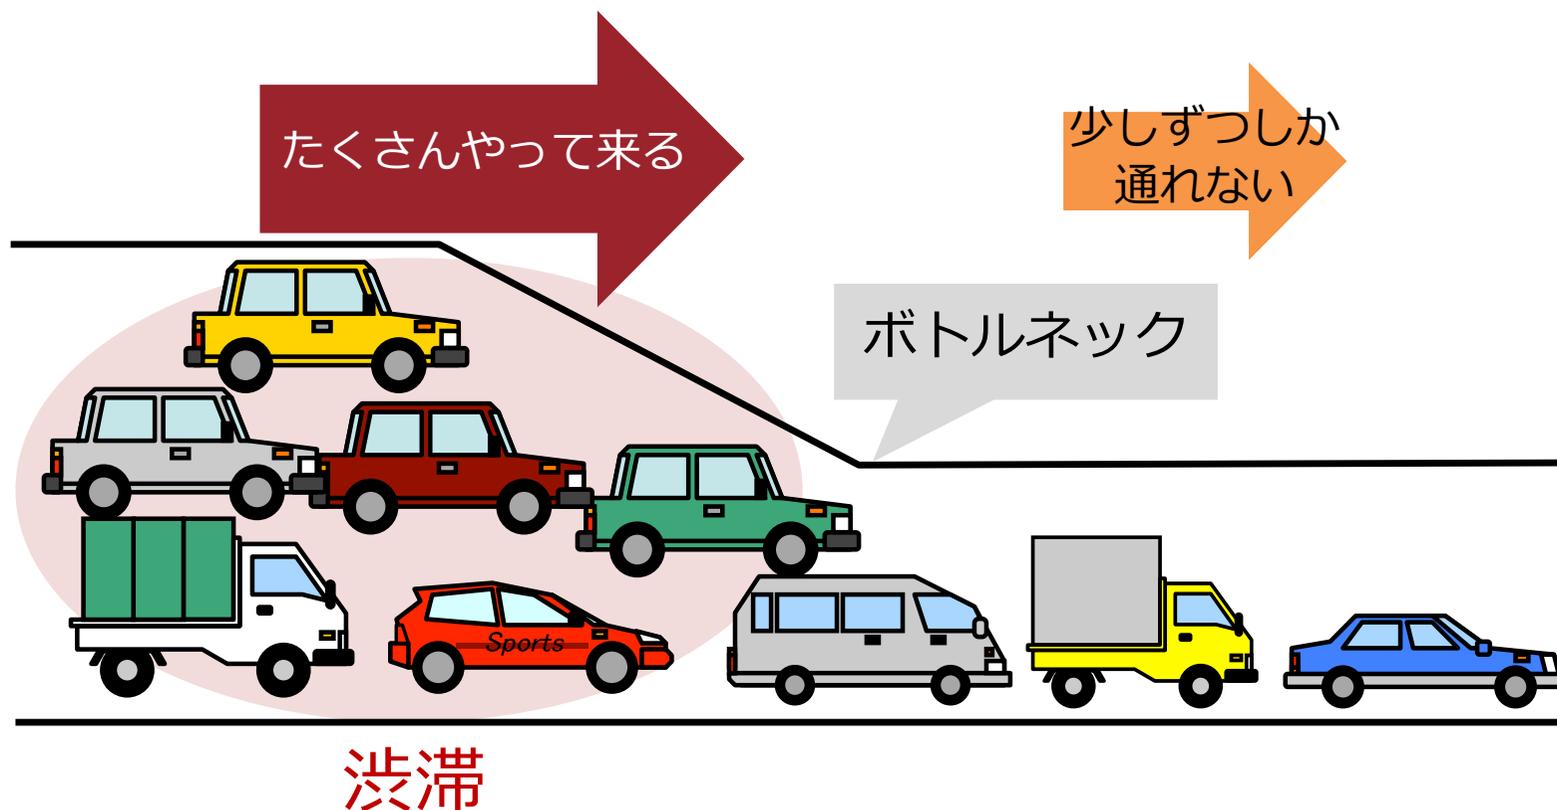
“道路分野では、約1.75億トンのCO2/年を
排出し、国内総排出量の約16%を占める”

渋滞の発生メカニズムと渋滞現象



交通渋滞の根本的原因

- 交通需要（単位時間あたりの流入してくる車両台数）とボトルネック交通容量（単位時間あたりに通過可能な車両台数）のバランス

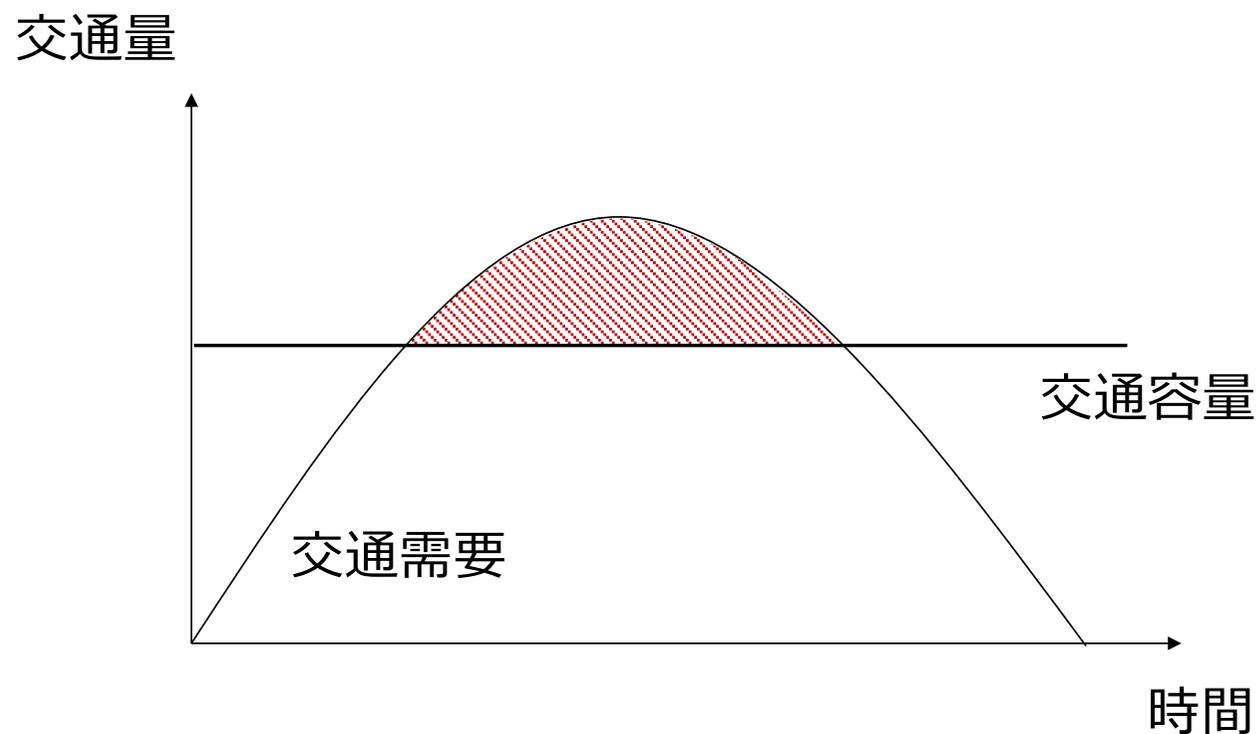


渋滞対策の考え方

ハード・ソフト
的に容量を拡大
する

交通需要を
空間的に分散さ
せる

交通需要を
時間的に分散さ
せる

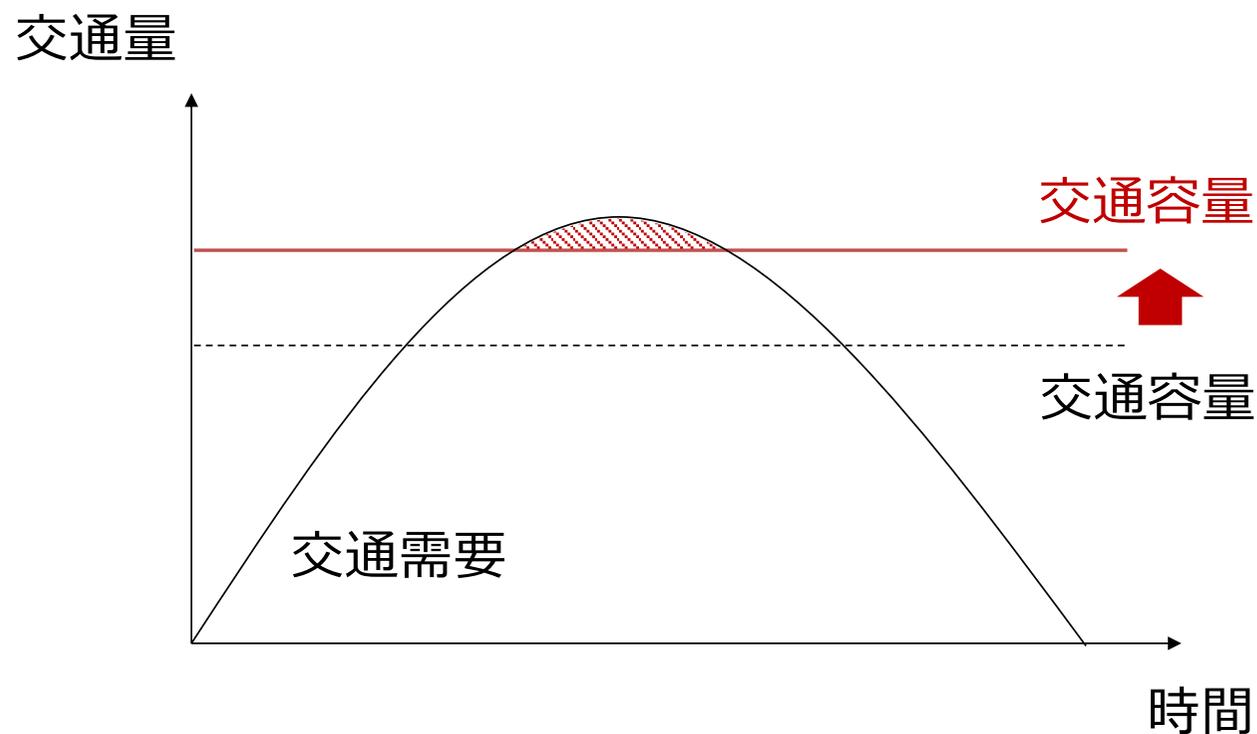


渋滞対策の考え方

ハード・ソフト
的に容量を拡大
する

交通需要を
空間的に分散さ
せる

交通需要を
時間的に分散さ
せる

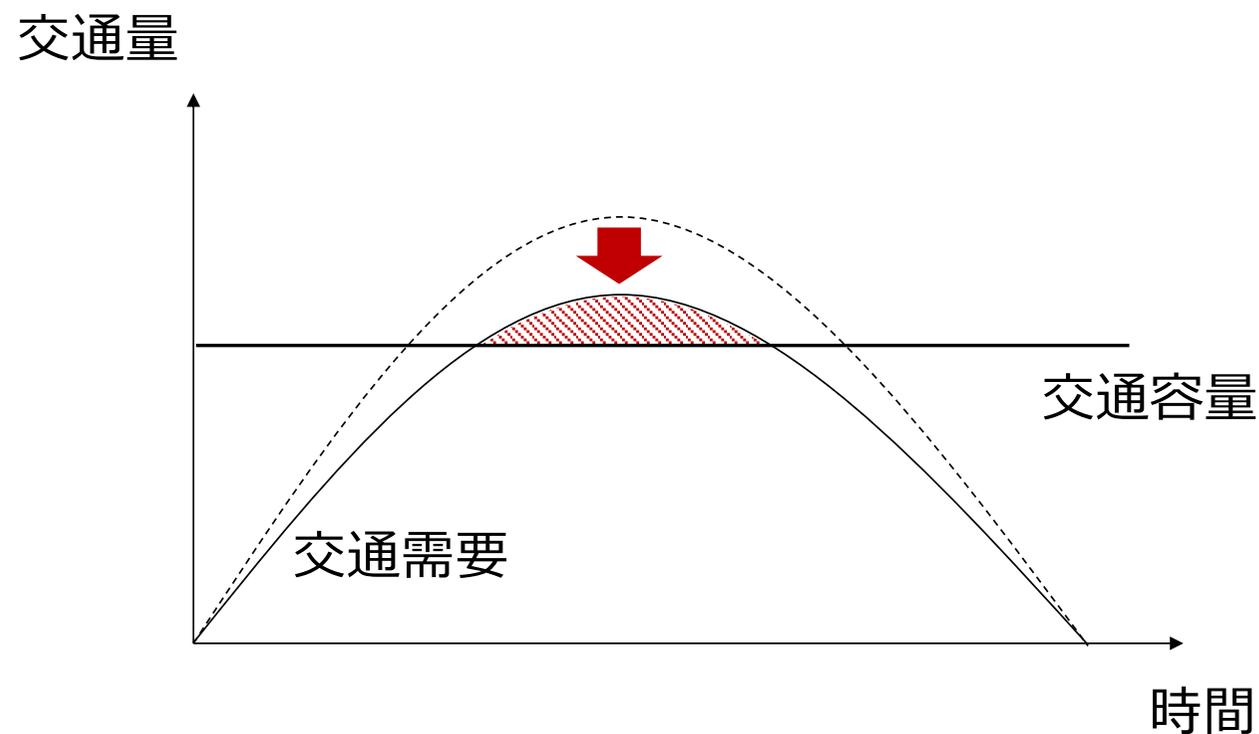


渋滞対策の考え方

ハード・ソフト
的に容量を拡大
する

交通需要を
空間的に分散さ
せる

交通需要を
時間的に分散さ
せる

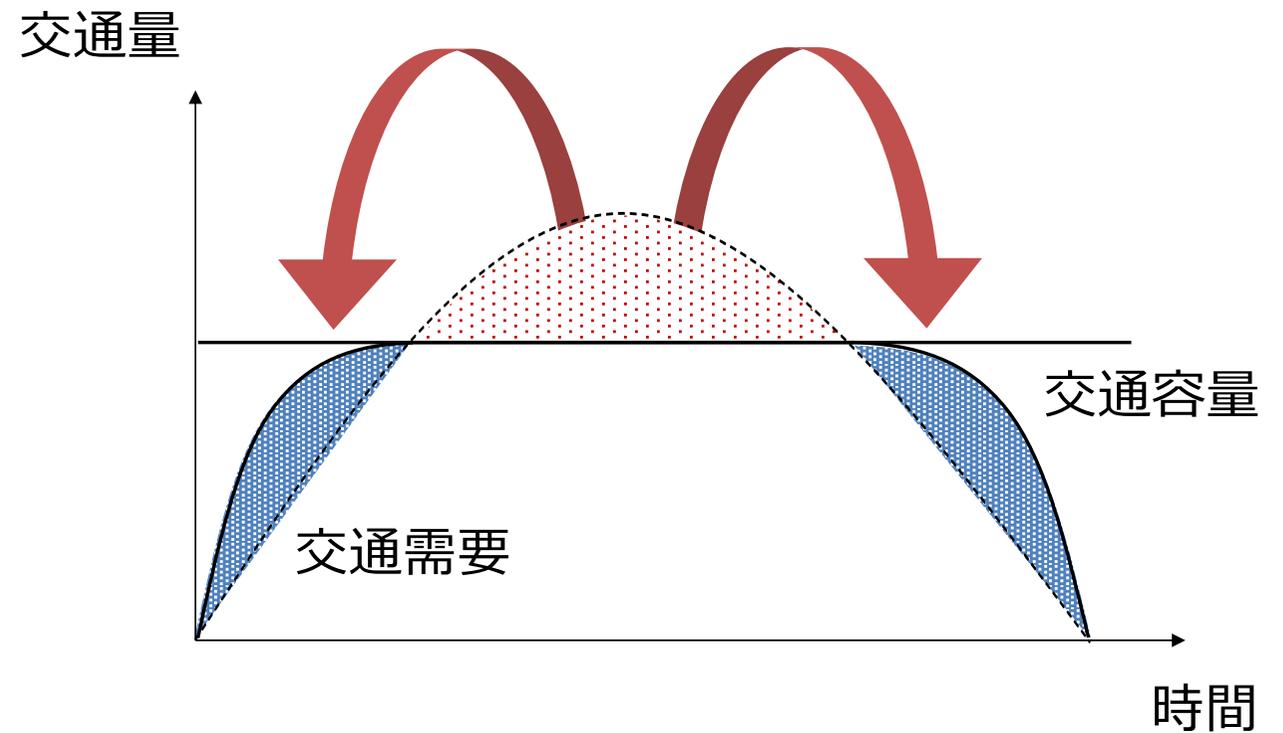


渋滞対策の考え方

ハード・ソフト
的に容量を拡大
する

交通需要を
空間的に分散さ
せる

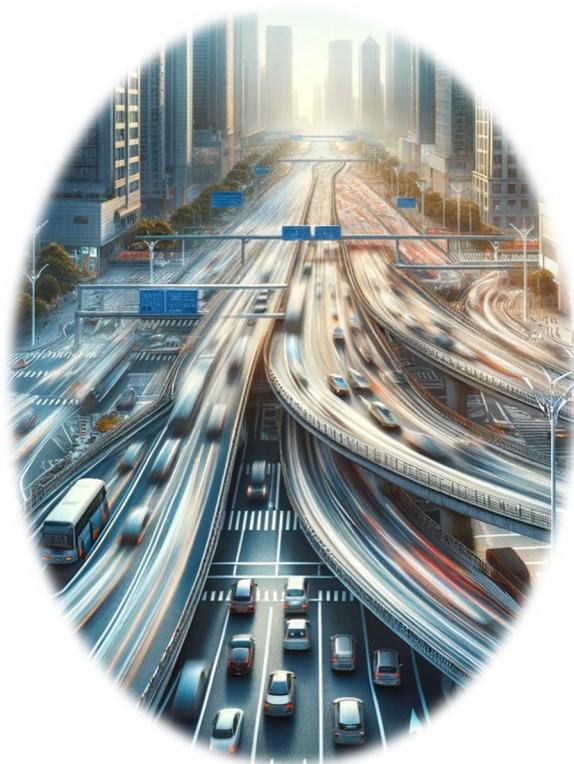
交通需要を
時間的に分散さ
せる



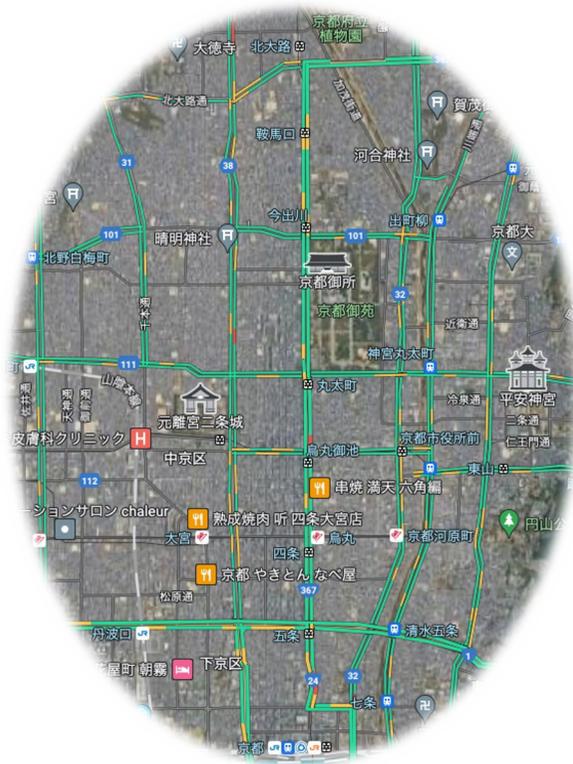
研究のアプローチ

• 交通流

供給



• 交通ネットワーク



• 交通行動

需要



データ収集と交通流理論の軌跡

データ収集と理論の軌跡

1930

1950

1960

1970

1980

1990

2000

2010

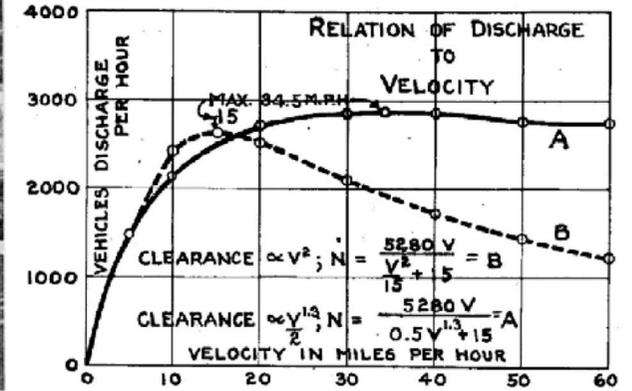
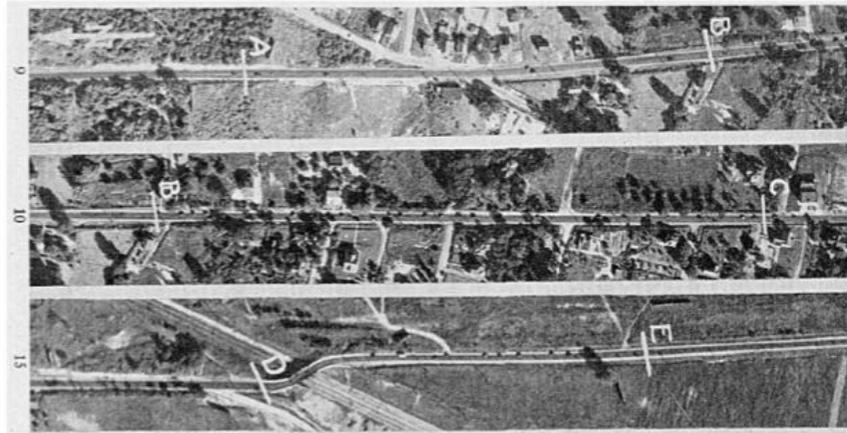
2020



Johnson (1928)

航空写真
連続写真

Fundamental
Diagram 1



Greenshields (1933)

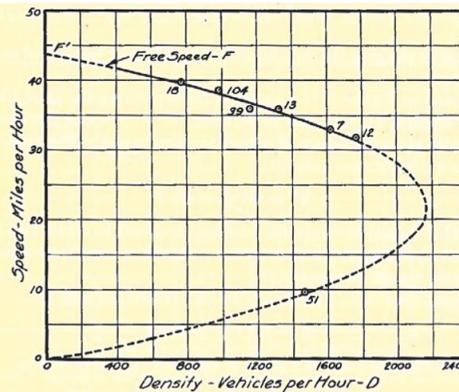
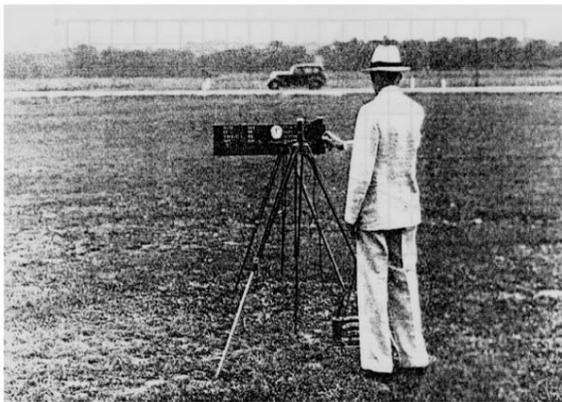
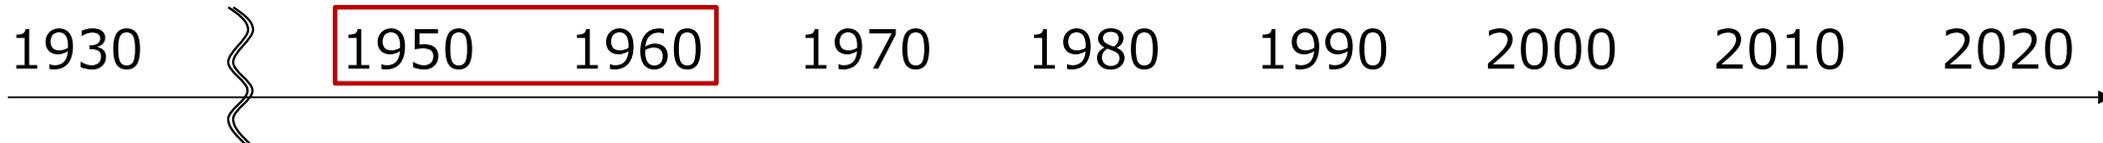


Figure 6. Speed in Miles per Hour Corresponding to a Given Density in Vehicles per Hour on a Two-lane Highway.

Density (密度)
Velocity (速度)
Discharge (交通量)

データ収集と理論の軌跡



ビデオカメラ
実走実験

統計分布

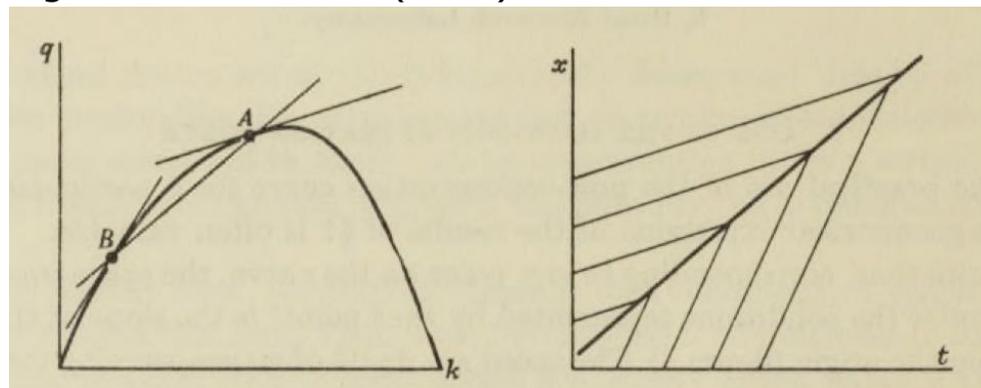
追従理論
Kinematic wave
theory

**理論はダイナミック
観測はスタティック**

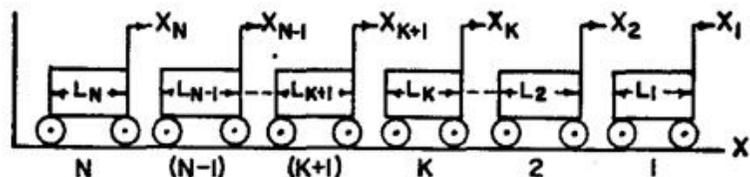
Kometani and Sasaki (1960)

pressure tank containing dye-stuff solution. Each of the lead car and the following car has under the floor one nozzle which injects ink, and you can inject dye-stuff solution from the nozzle to make the position of the vehicle on the road surface continuously while they run on the car following experiment. At the same time, every 0.20 sec. time pulse marks

Lighthill and Whitam (1955)



Pipes (1953)



データ収集と理論の軌跡

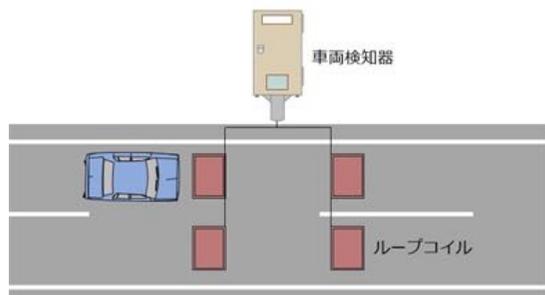


車両感知器

相転移, 粗密波, ヒステレシス
キャパシティドロップ

追従・車線変更
2nd order...

シミュレーション

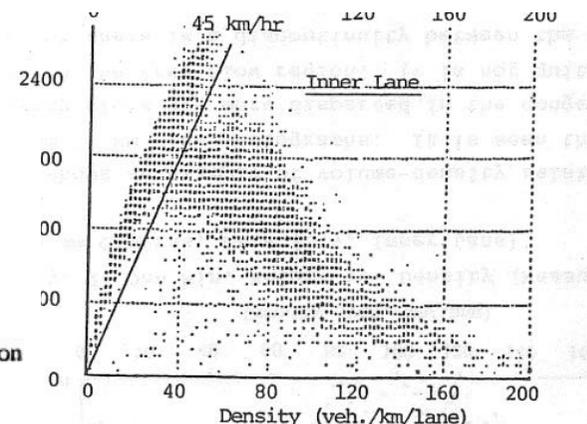
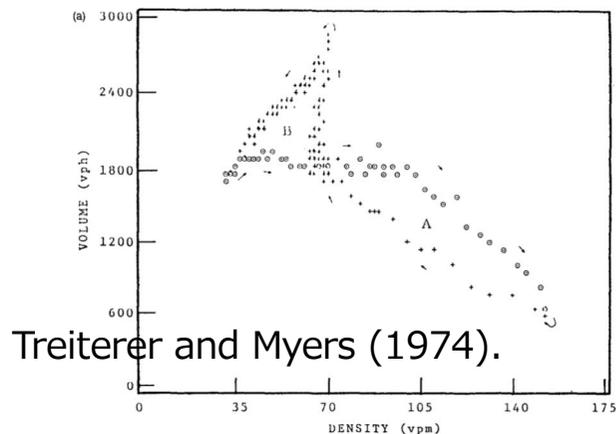
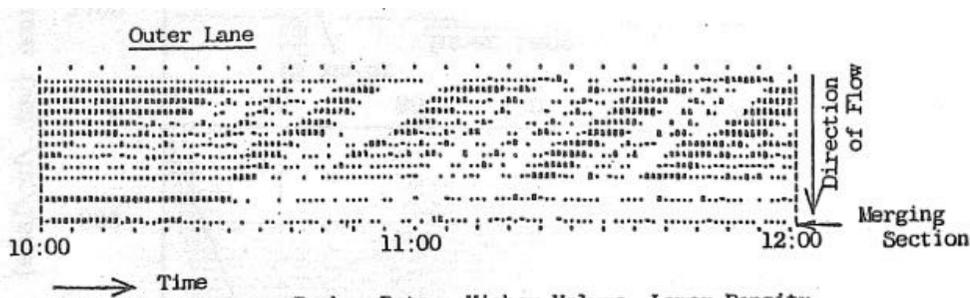


ループコイル式
車両感知器



超音波式
車両感知器

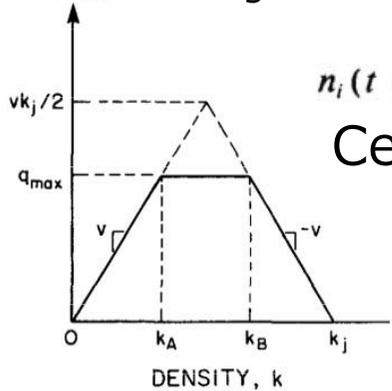
Koshi et al. (1981)



データ収集と理論の軌跡



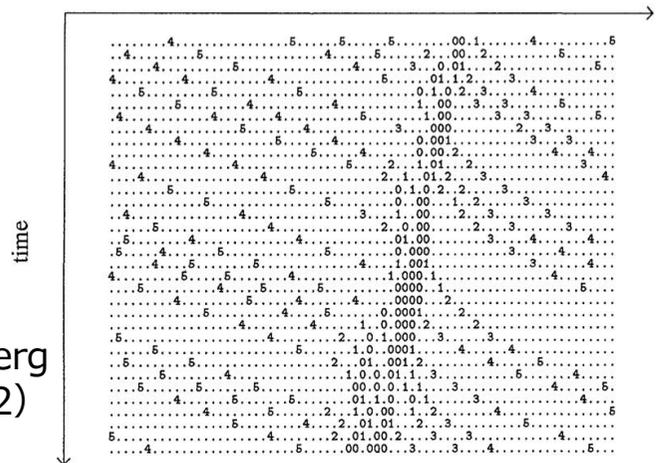
Daganzo (1994)



$$n_i(t+1) = n_i(t) + y_i(t) - y_{i+1}(t)$$

Cell Transmission (CTM)

space (road)

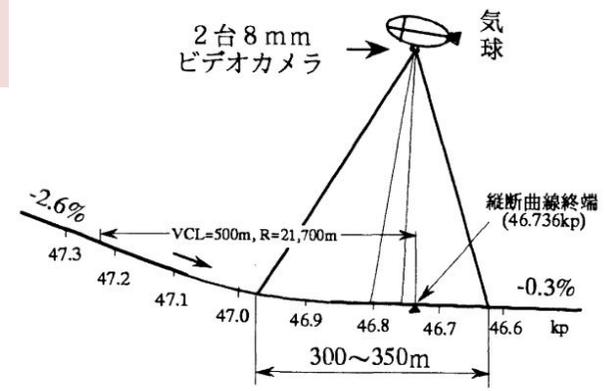


Nagel and Schreckenberg (1992)

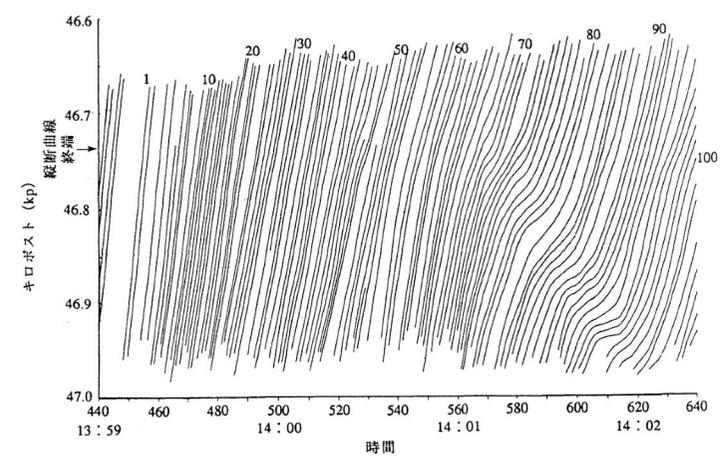
車両感知器
航空画像

サグ

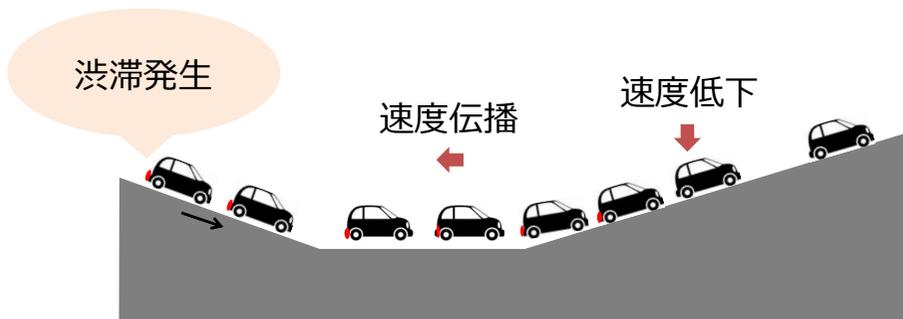
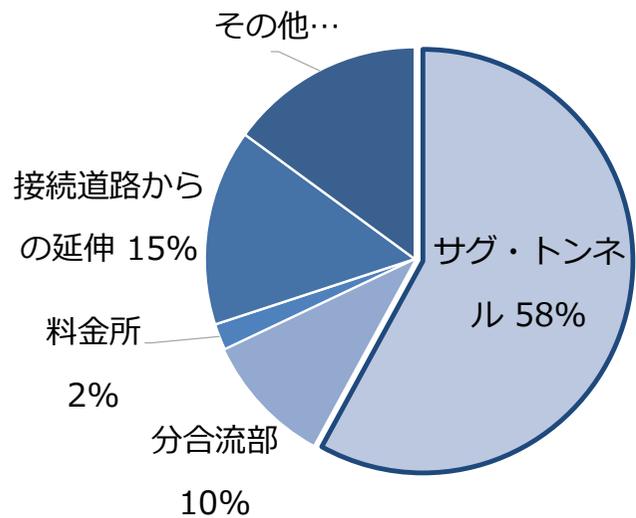
Gas-kinetic
CA
シミュレーション



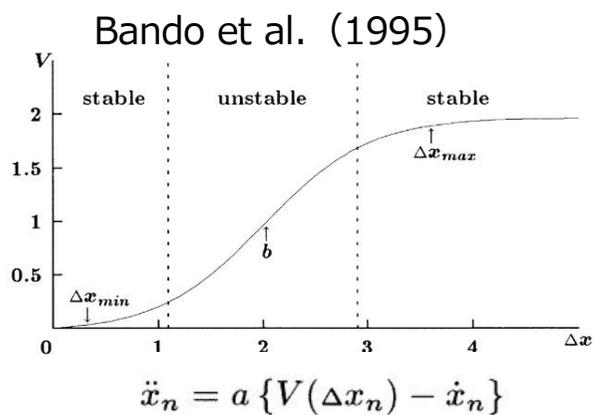
邢・越 (1995)



サグでの渋滞



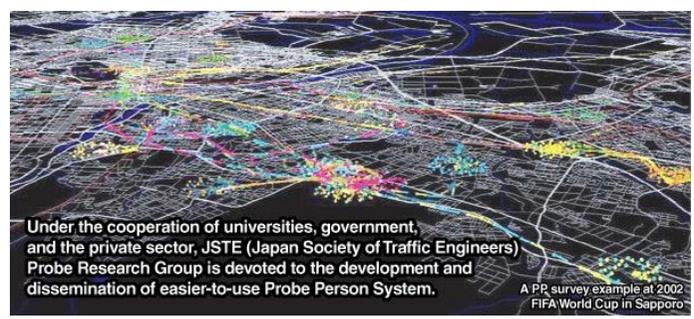
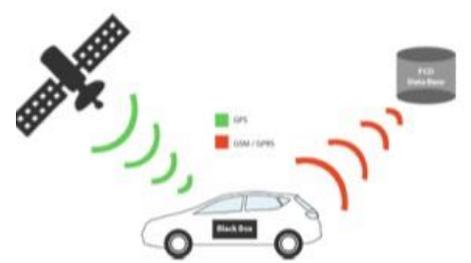
データ収集と理論の軌跡



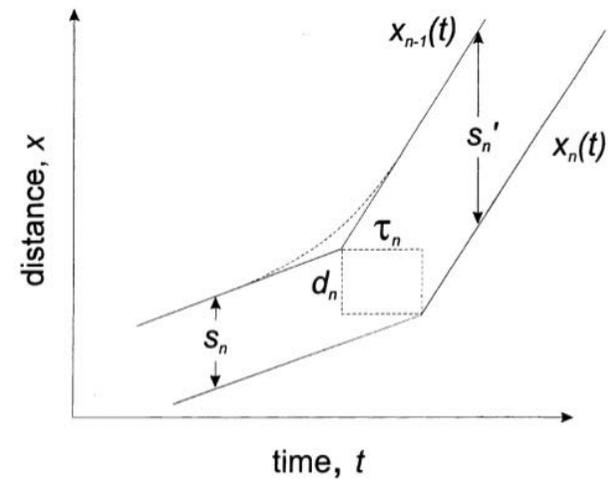
車両感知器, プローブ
ドライビングシミュレーター

相転移現象

String stability
Simplified Newell



Newell (2002)



データ収集と理論の軌跡



NGSIM (2006)

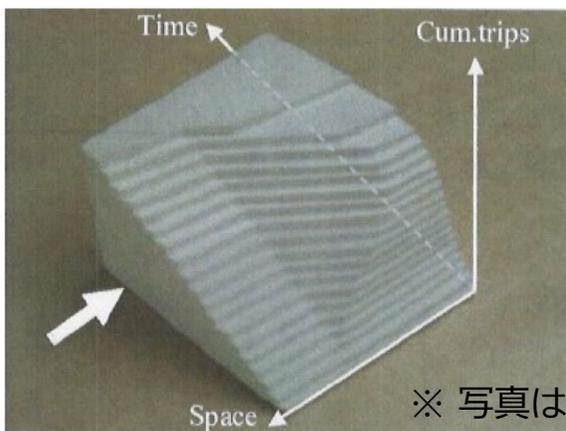


GPS (プローブ)
画像解析

MFD

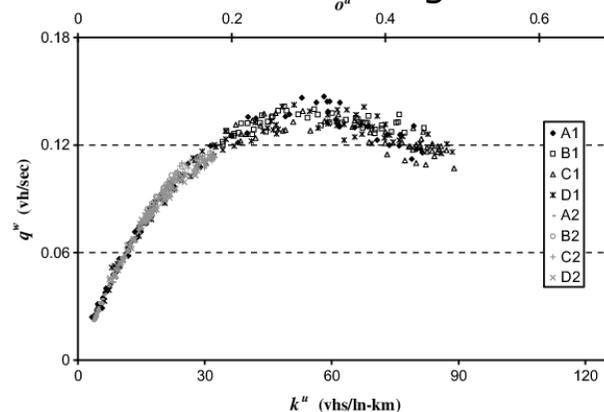
ACC/CACC
Lagrangian
expansion

Variational theory (VT) Daganzo (2005)

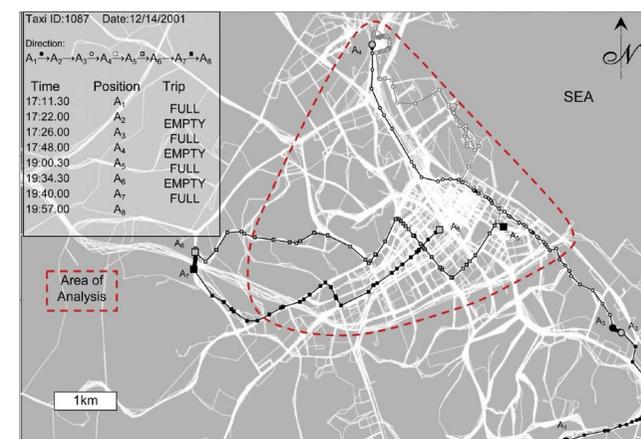


※ 写真は桑原による

Macroscopic
Fundamental Diagram



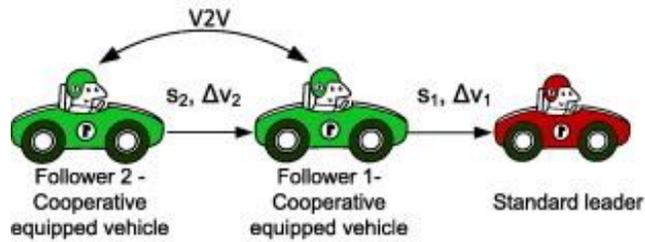
Geroliminis and Daganzo (2007)



データ収集と理論の軌跡



Wang et al. (2014)



pNEUMA (2020)

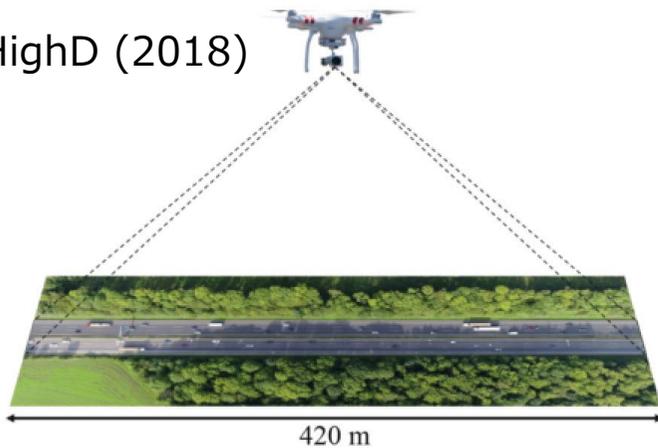


オープンソース
走行軌跡データ

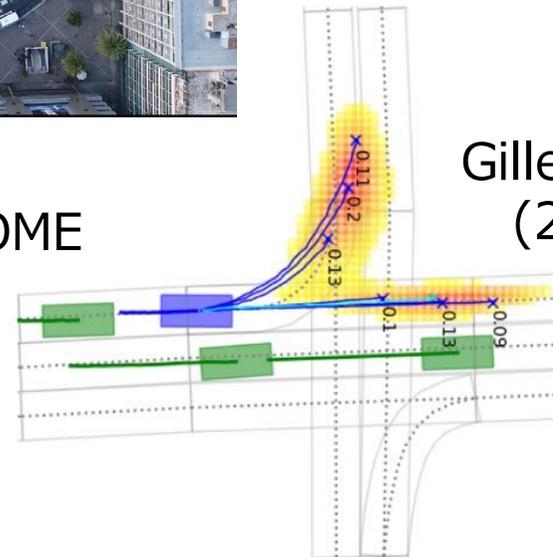
ウィーナー過程

ACC/CACC
データ駆動・AI

HighD (2018)

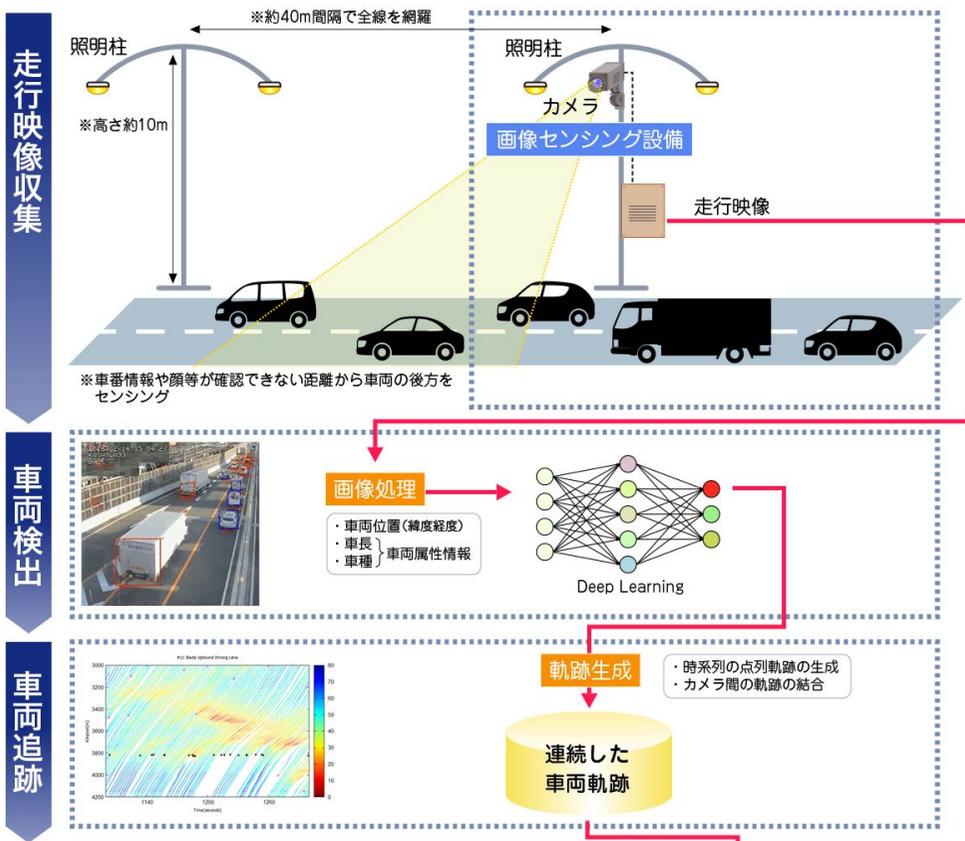


HOME



Gilles et al. (2021)

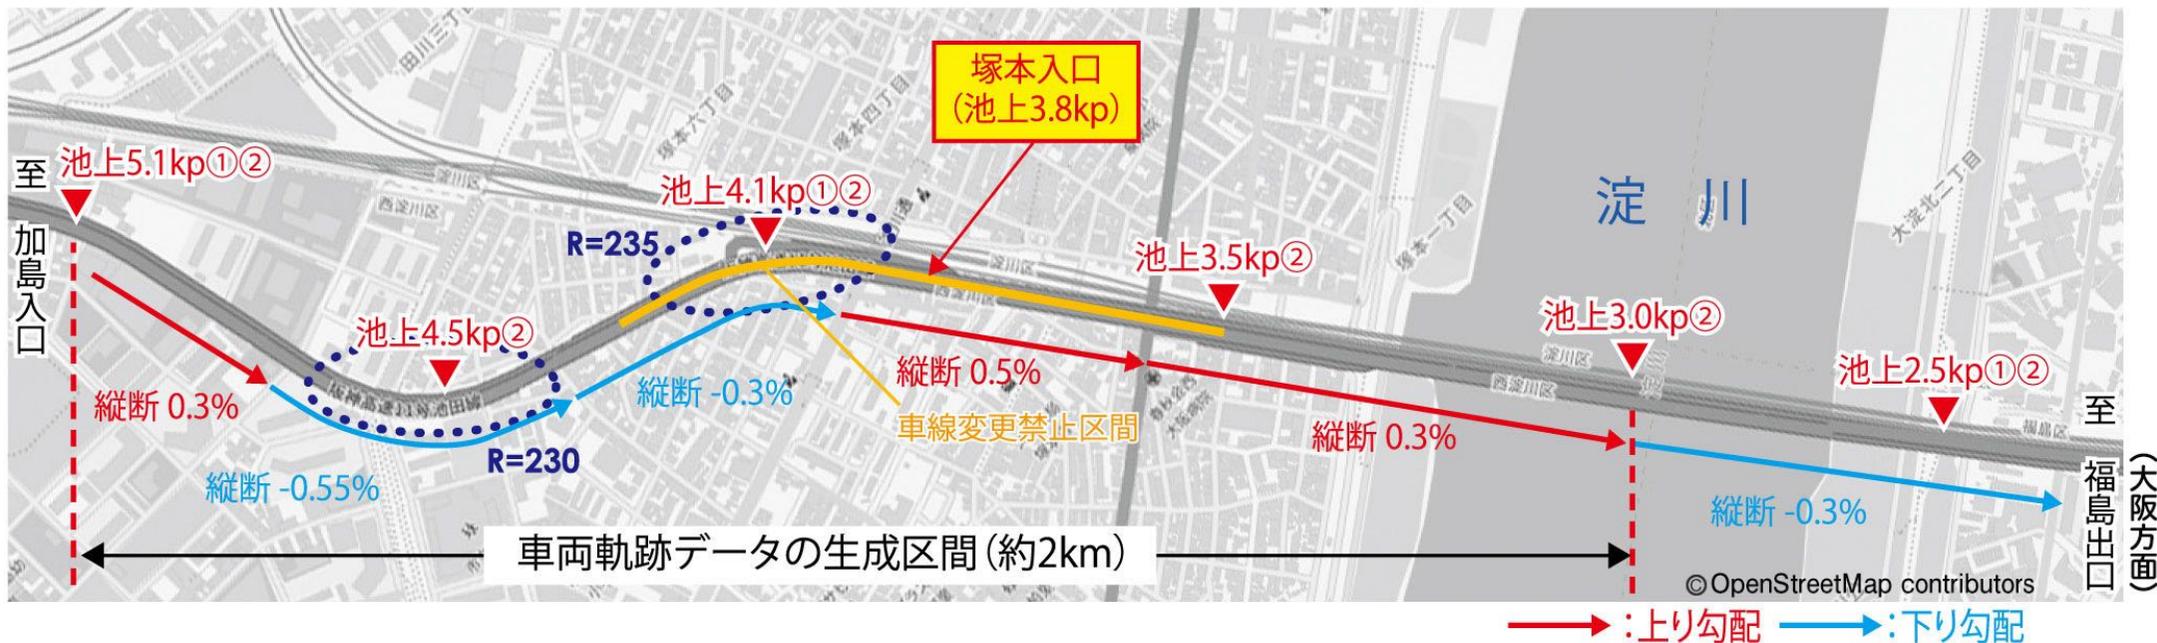
交通流の観測ーサンプルから全数へー



交通流の観測

- 阪神高速道路がすべての車両の走行軌跡の観測データを公開
 - ZTD (走行軌跡データ) : 阪神高速 11号池田線

▼ : 車両検知器設置位置 (番号は設置車線)



交通流の観測

- 阪神高速道路がすべての車両の走行軌跡の観測データを公開
 - ZTD (走行軌跡データ) : 阪神高速 11号池田線



交通流の観測

- 阪神高速道路がすべての車両の走行軌跡の観測データを公開
 - ZTD (走行軌跡データ) : 阪神高速 11号池田線



データ駆動型追従モデルによる 加減速挙動の確率的特性の分析

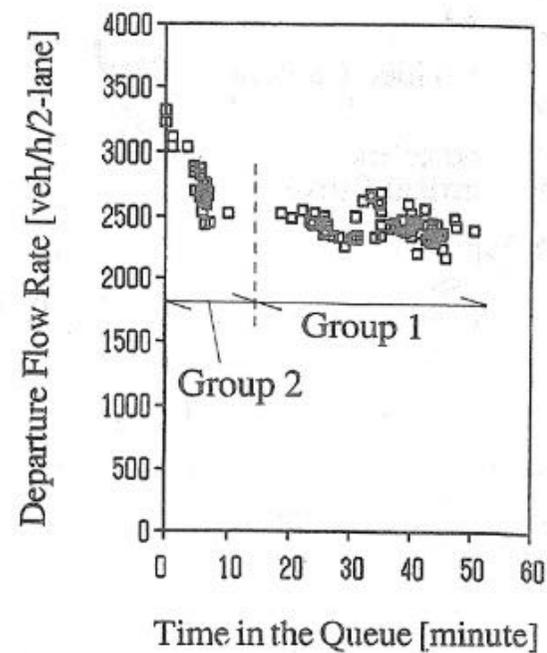
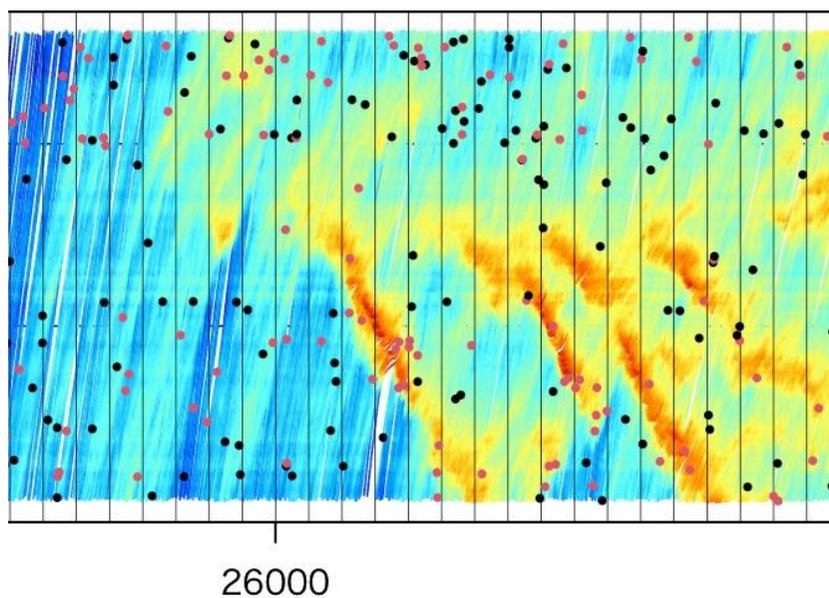
塩見 康博 (立命館大学)

Guopeng Li (TU Delft)

Victor L. Knoop (TU Delft)

単路部での渋滞現象

- 交通マネジメントを実施する上で対象とすべき事象
 - 疎密波 (Stop-and-go wave)
 - 交通容量低下現象 (Capacity drop)
 - 渋滞転移 (Instability)



単路部での渋滞現象

- 運転挙動の**確率的なばらつき**

- 疎密波 (Stop-and-go wave) : Laval, Toth and Zhou (2014)
- 交通容量低下現象 (Capacity drop) : Yuan et al. (2019)
- 渋滞転移 (Instability) : Ngoduy et al. (2019)

従来の考え方

$$\text{加速度} = f(\text{速度差} \cdot \text{車間距離等} | \text{パラメータ})$$

ここが確率的に分布
(=個人差)

上の論文の考え方

$$\text{加速度} = f(\text{速度差} \cdot \text{車間距離等} | \text{パラメータ}) + \text{確率項}$$

ここは固定 微妙な変動を考慮
(=認知・操作ミス)

単路部での渋滞現象

- 運転挙動の確率的なばらつき
 - 疎密波 (Stop-and-go wave) : Laval, Toth and Zhou (2014)
 - 交通容量低下現象 (Capacity drop) : Yuan et al. (2019)
 - 安定性 (Instability) : Ngoduy et al. (2019)

$$dv(t) = \underbrace{(v_c - v(t))\beta dt}_{\text{希望速度に近づく
ほど加速しなくなる}} + \underbrace{\sigma dW(t)}_{\text{ブラウン運動
(ホワイトノイズ)}}$$

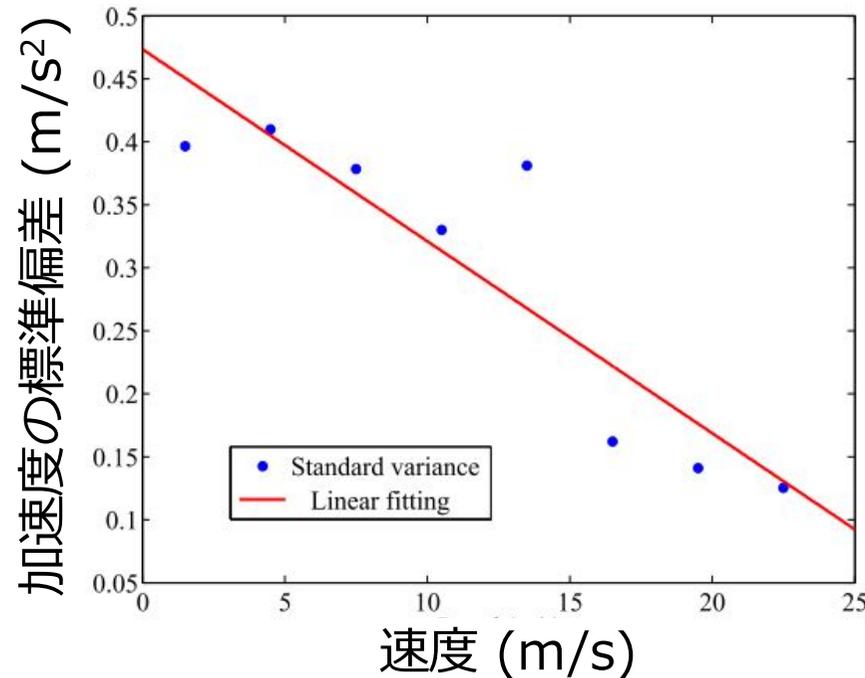
▶ Capacity dropは
再現されず…

$$dv(t) = \underbrace{(v_c - v(t))\beta dt}_{\text{希望速度に近づく
ほど加速しなくなる}} + \underbrace{(v_c - v(t))\sigma dW(t)}_{\text{ブラウン運動
(=希望速度に近づくと
走りが安定する)}}$$

▶ Capacity drop
が再現！！

追従モデルの確率項の論拠

- 停止状態から発進する過程の速度・加速度のデータを収集 (Laval et al., 2014)



速度が上がると
加速度の標準偏差も
下がる???

$$dv(t) = \underbrace{(v_c - v(t))\beta dt}_{\text{希望速度に近づく}} + \underbrace{(v_c - v(t))\sigma dW(t)}_{\text{幾何ブラウン運動}} \quad (= \text{希望速度に近づくとき走り安定する})$$

希望速度に近づく
ほど加速しなくなる

幾何ブラウン運動
(= 希望速度に近づくとき
走りが安定する)

明らかにしたいこと

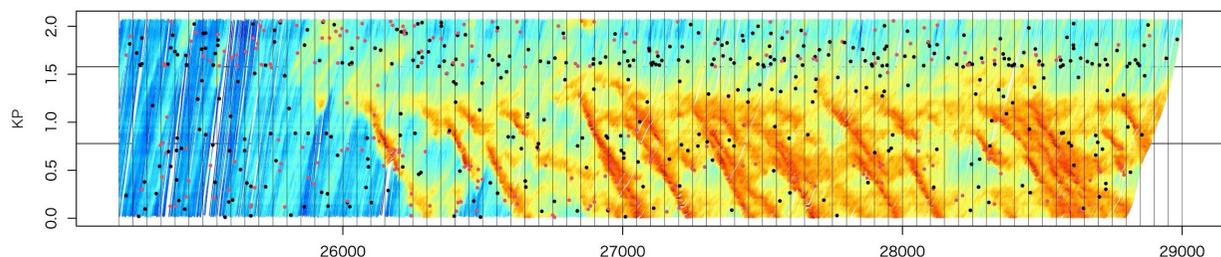
交通状態と“ドライバーの運転挙動の確率的なばらつき”の観測
個人差 + 個人内での変動（認知・操作誤差）



- 追従モデルにおける確率項の妥当性
- 交通状態と挙動のばらつきの関係性
- 不確実性の理解に基づく、交通マネジメントへの示唆

方法

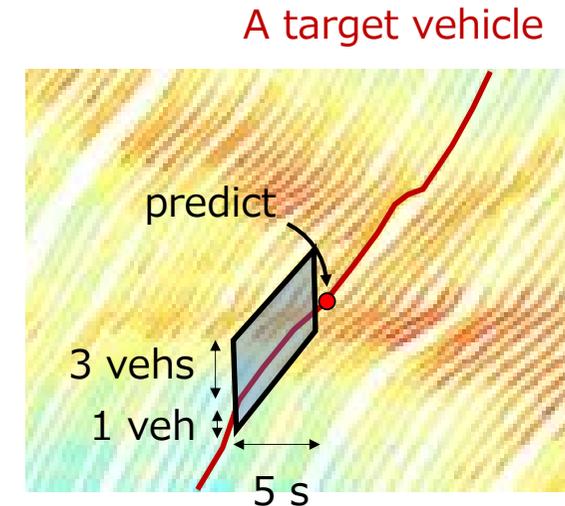
- × 同じ状況で同じ人に何度も繰り返し運転してもらい、それぞれの時点の加速度の分布を調べる
- 精度良く 加速度の確率分布 を推定するモデルを構築し、その分布形状や標準偏差と交通状態の関係を調べる
- 5時間分のZTD@池田線を用いて確率分布を出力する深層学習モデルの構築
(今回は追越車線のみ)



Site	No	Day & time	Unique ID	No of records
Line 11	1	Weekday 7:00-8:00	2,164	3,169,367
	2	Weekday 15:00-16:00	2,121	2,258,147
	3	Holiday 10:00-11:00	1,898	2,515,658
	4	Weekday 7:00-8:00	2,225	3,188,724
	5	Weekday 15:00-16:00	1,998	2,329,178

LSTMの設定

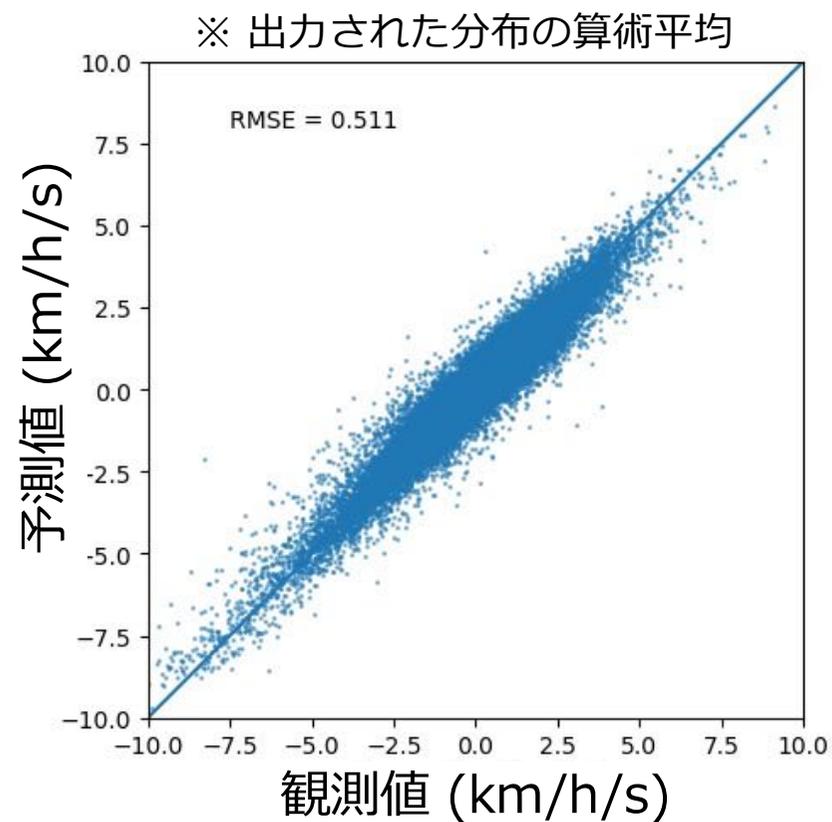
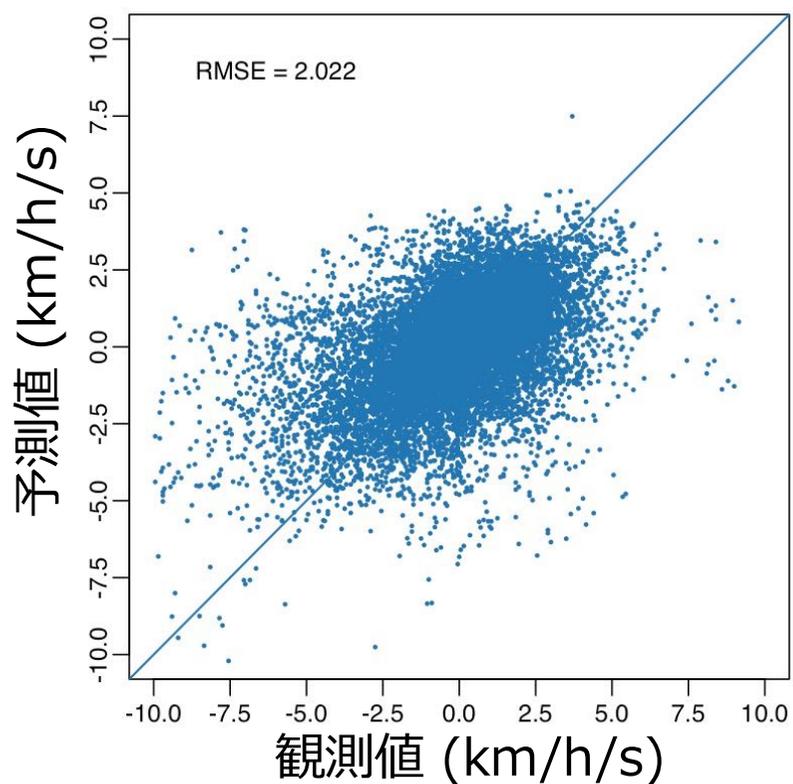
- 入力変数（過去5秒間分）
 - 自車・前方3台・後方1台の車種, 車長, 速度, 加速度, 相対速度
 - 50m前方の曲率半径
 - 前後100m内の平均勾配
 - 休日ダミー
 - タピークダミー
 - 車線変更禁止区間ダミー
- 学習用データ
 - ランダムに80%の軌跡を抽出してTraining（8割）・Validation（2割）に利用
 - 残りの20%でテスト



Batch size is 6 512; the number of hidden layers of LSTM is 32; optimizer is Adam; learning rate is scheduled 7 with initial learning rate, 0.01, decay rate, 0.9, and decay steps, 10,000; γ and α of Focal Loss function are 8 2.0 and 0.25. In total, 41,225 parameters to be trained.

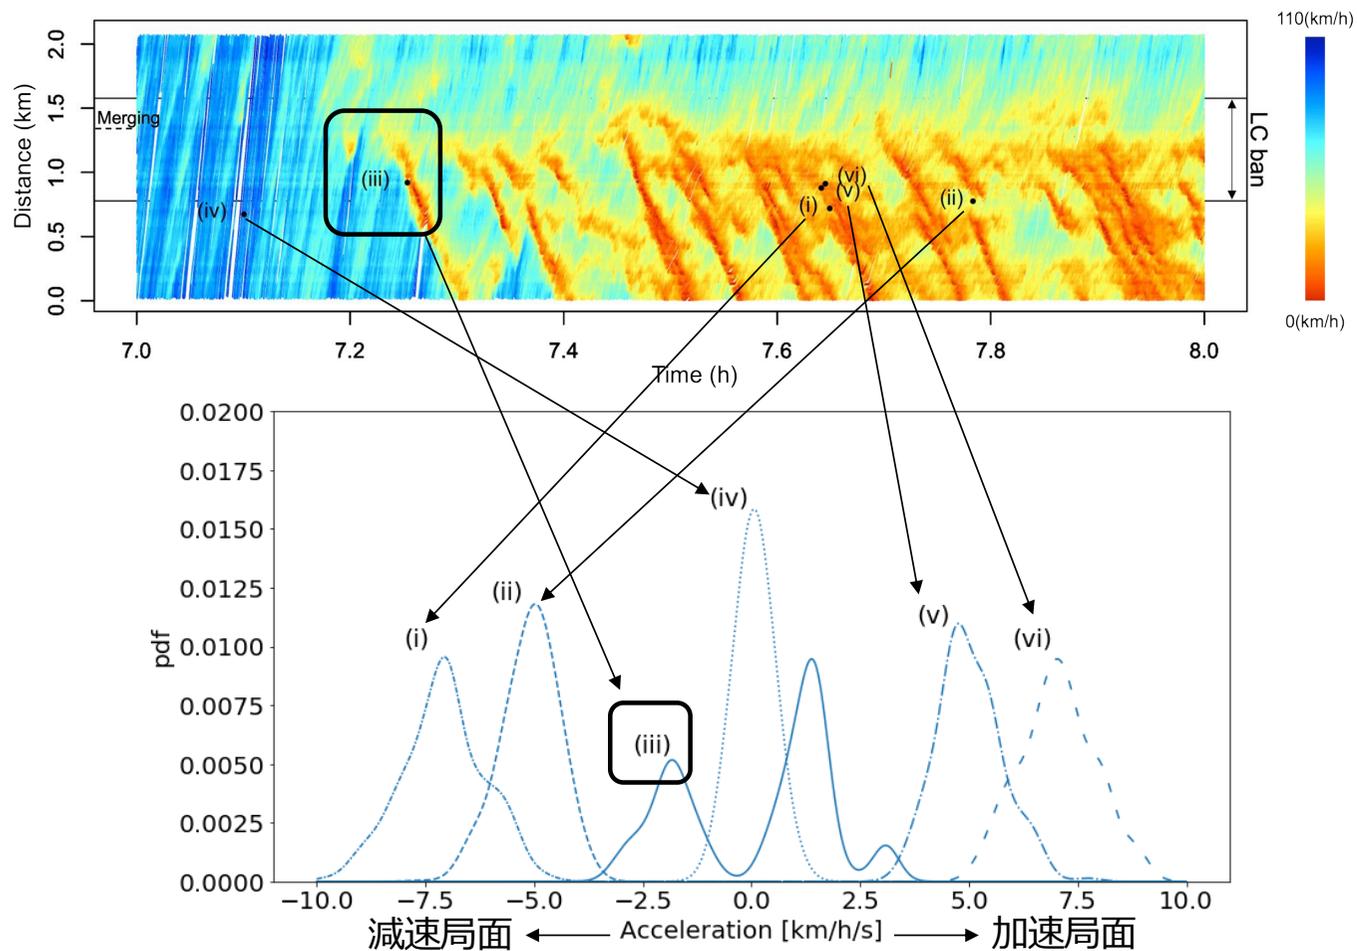
テスト結果

- ベンチマーク：各軌跡について80%のデータでパラメータ推定し，残りの20%でテストをしたHelly model
- 提案モデル：テストに用いたデータ中には，学習で用いた車両は含まれない



推定された加速度分布の形状

- カーネル密度分布



(iii)は多峰性の分布

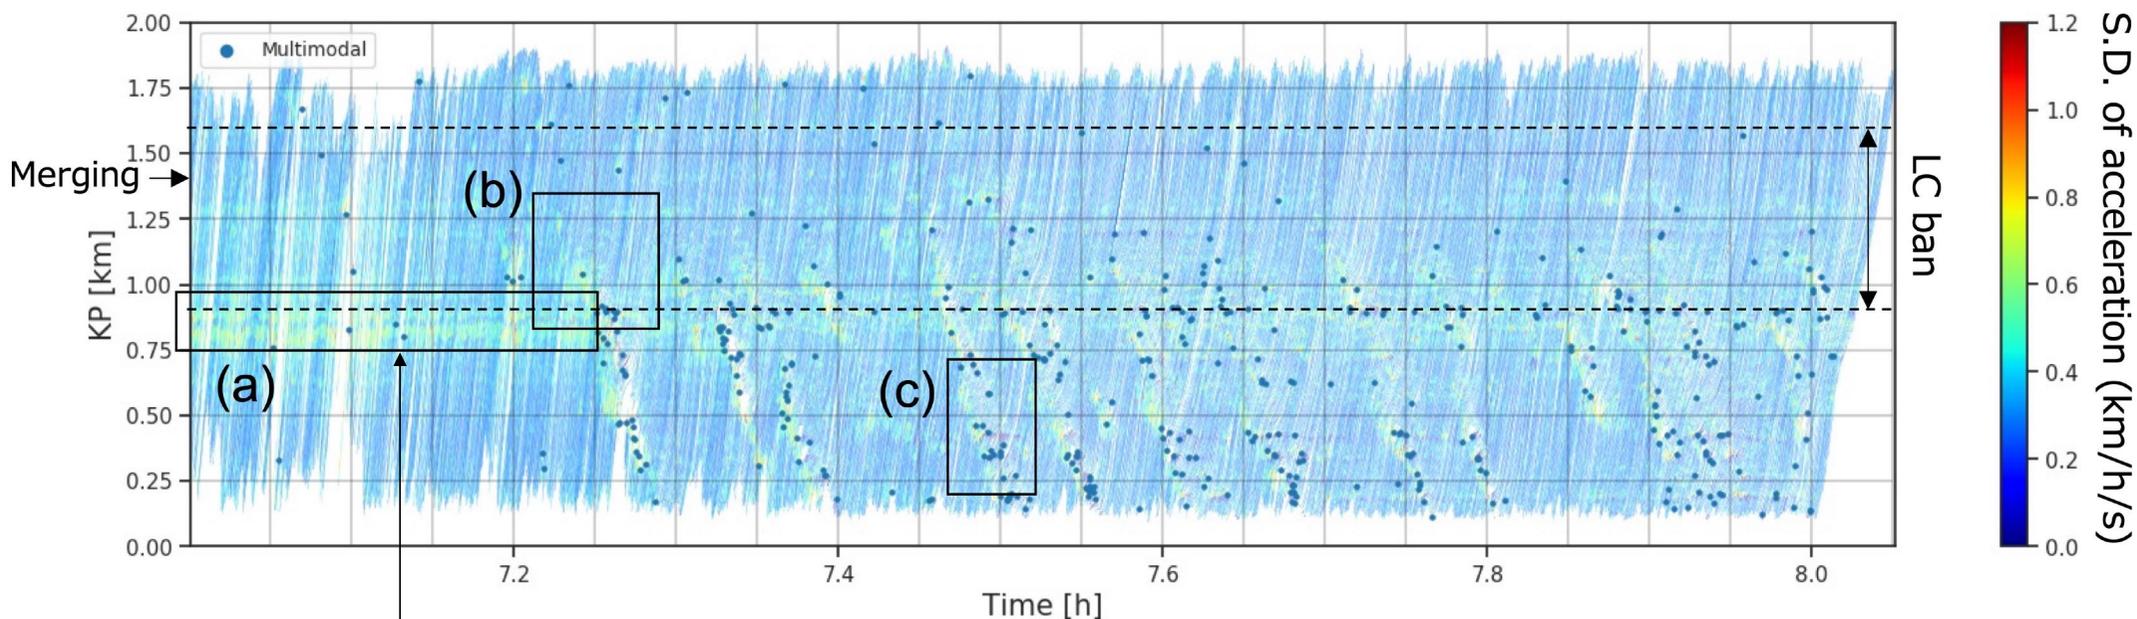


将来シナリオの
分岐点？

加速度分布標準偏差の可視化

- 標準偏差で軌跡を色付け（暖色系ほど加速度の不確実性が高い）

※ ● は多峰分布と推定された地点

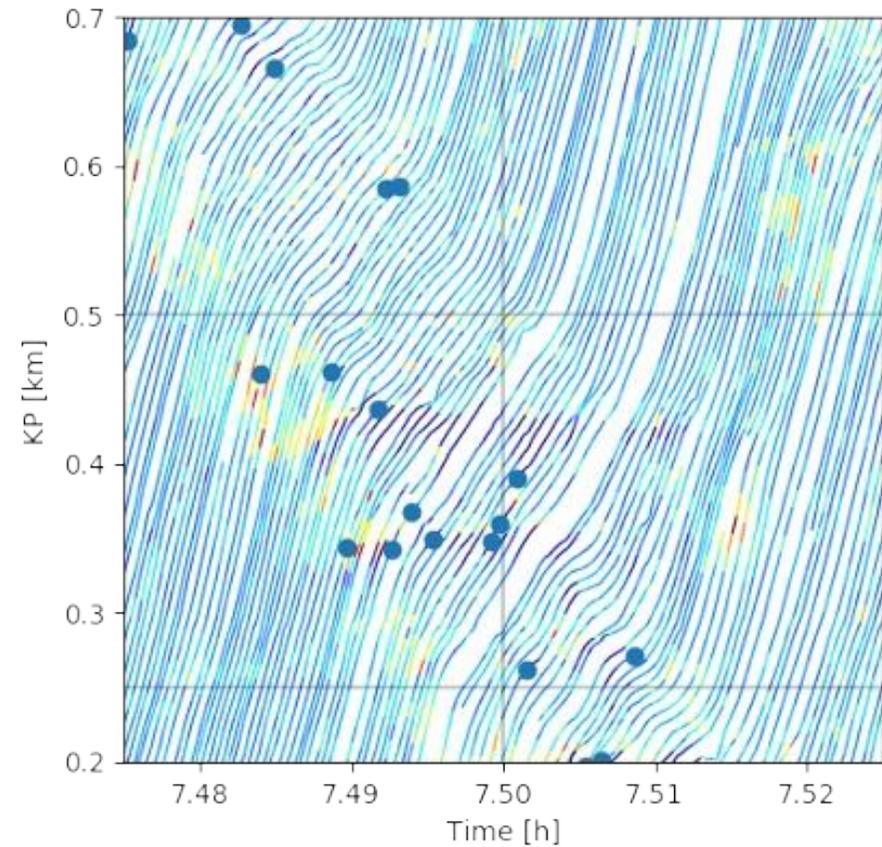
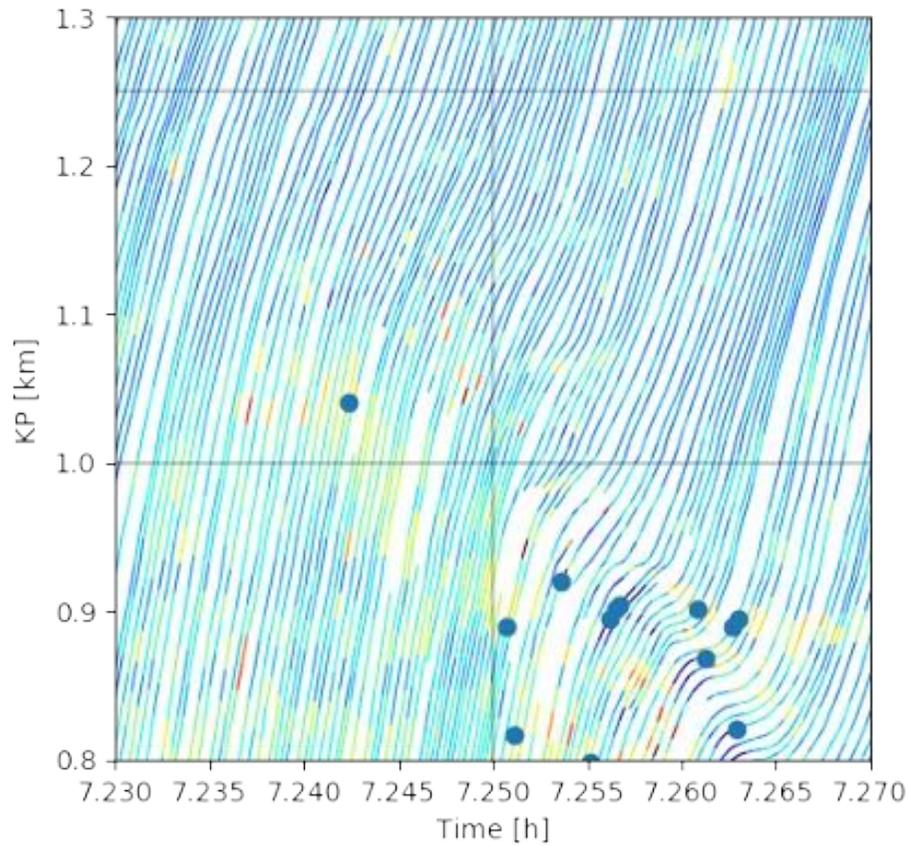


車線変更禁止区間の手前で分散大きい ▶

車線変更車両の受け入れ可否により多様性が顕著

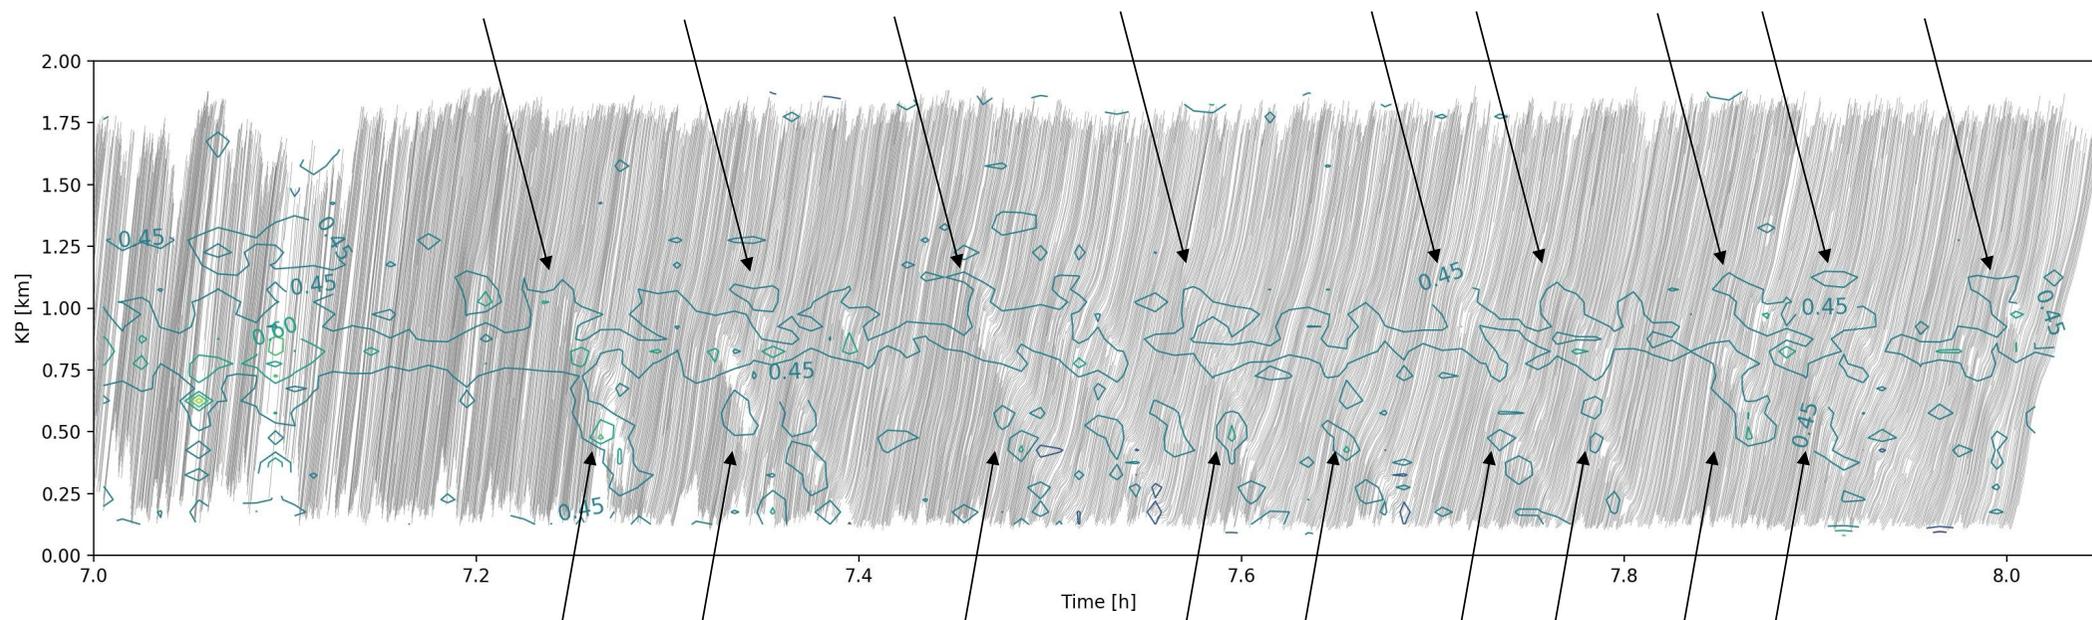
加速度分布標準偏差の可視化

- 標準偏差で軌跡を色付け（暖色系ほど加速度の不確実性が高い）



加速度分布標準偏差のコンター図

疎密波が発生する上流地点で加速度の標準偏差が大きくなる傾向



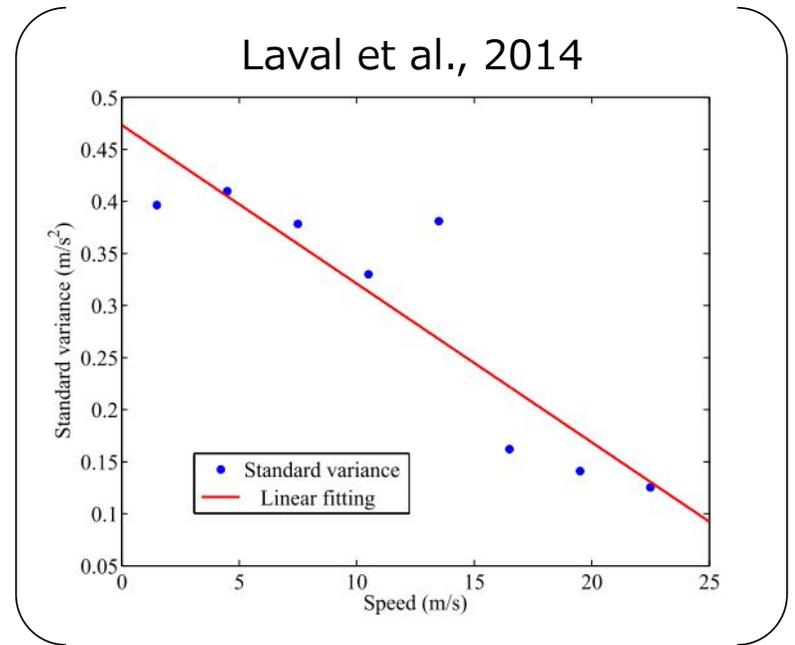
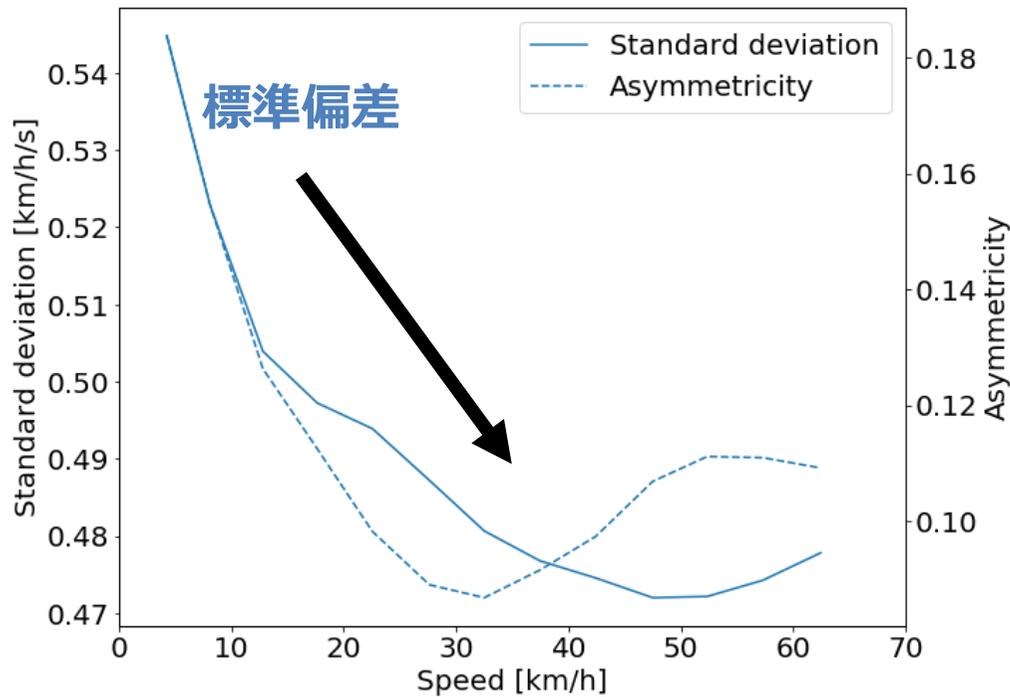
疎密波に差し掛かる地点で加速度の標準偏差が大きくなる傾向



疎密波の発生・伝播と加速挙動のばらつきに一定の関係性がある可能性

速度と加速度標準偏差の集計分析

- 加速局面**において，速度レベルごとに加速度標準偏差の平均を集計
 - 速度の上昇とともに分布の幅は減少する傾向（Yuan et al. 2019を支持）
 - 極端に強く加速するドライバーの存在



まとめ

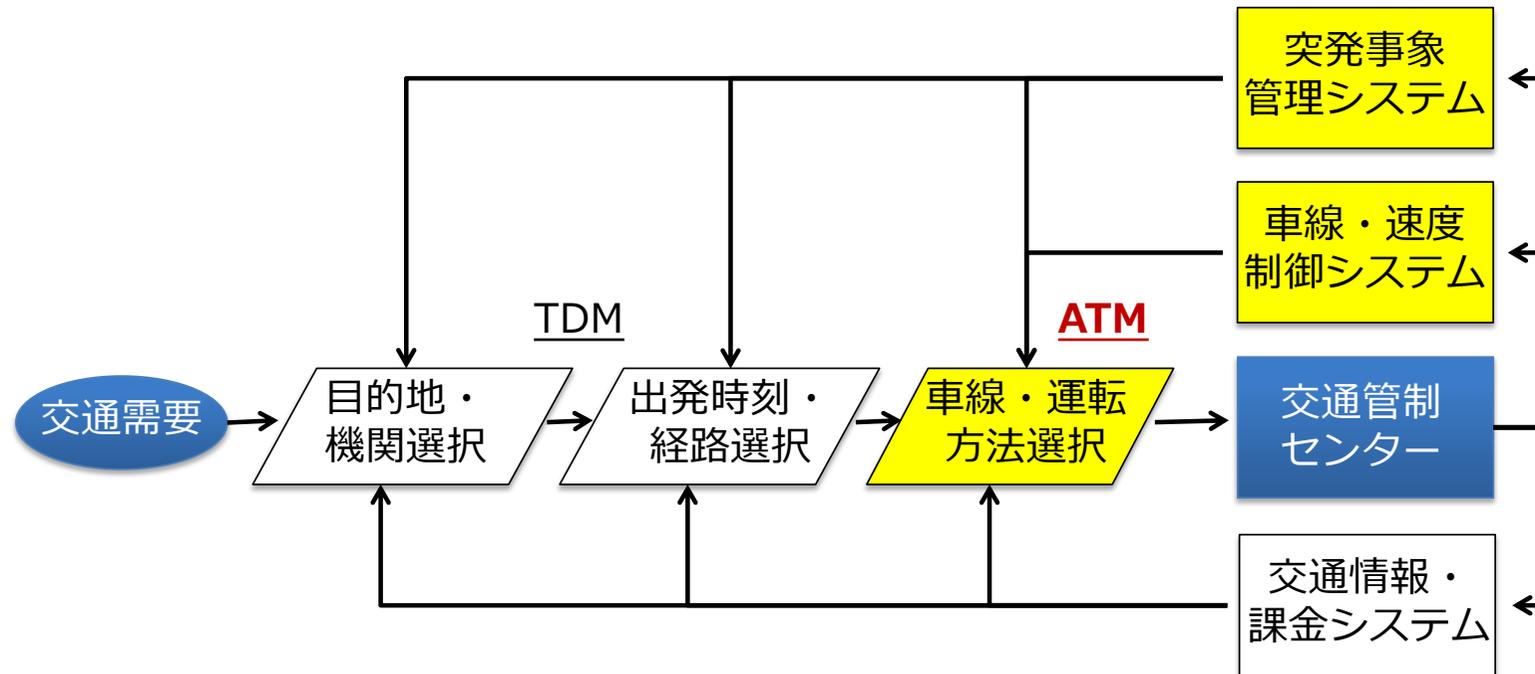
- 加減速挙動のばらつきを可視化
 - ばらつきの増大と交通流の不安定性に一定の関係性がある可能性
 - 既往の知見との整合性
 - 運転操作のばらつきを解消する対策の有効性
 - ← 可変制限速度制御 (VSL, Variable Speed Limit)
- 本モデルをベースとしたシミュレーションの実施
 - 誤り伝播への対処
- 他地点への適用可能性
 - ファインチューニング・転移学習によるモデルのアップデート
- 車線変更挙動への拡張
 - 車線変更強度と交通状態の関係性

コネクティッド自動運転車両を考慮した深層強化 学習による可変制限速度制御

首都高速道路（株） 藤本 想
立命館大学 塩見 康博

アクティブトラフィックマネジメントとは？

- Active Traffic (and Demand) Management : AT(D)M
 - 動的かつ能動的な交通流（交通需要）マネジメント
 - 交通状況のオンライン・モニタリングとそれに応じたコントロールにより，需要を抑制しかつ交通容量の増大を図る施策
(HCM 2010)

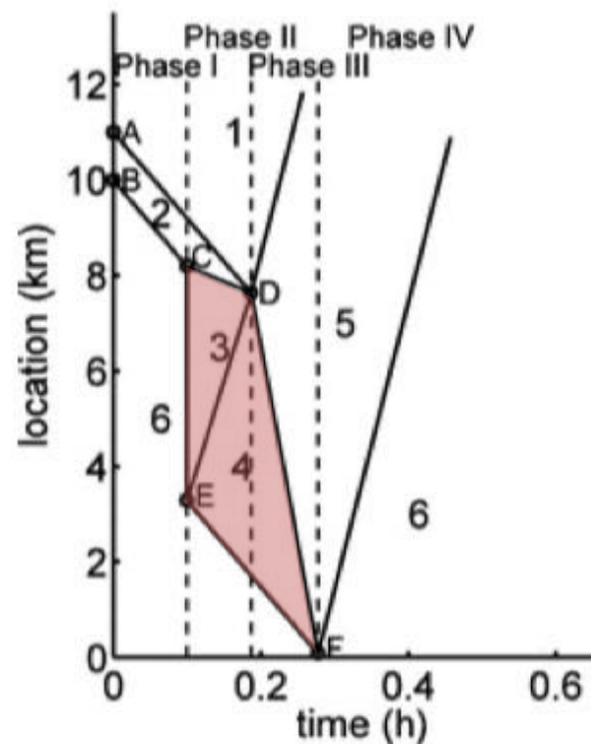
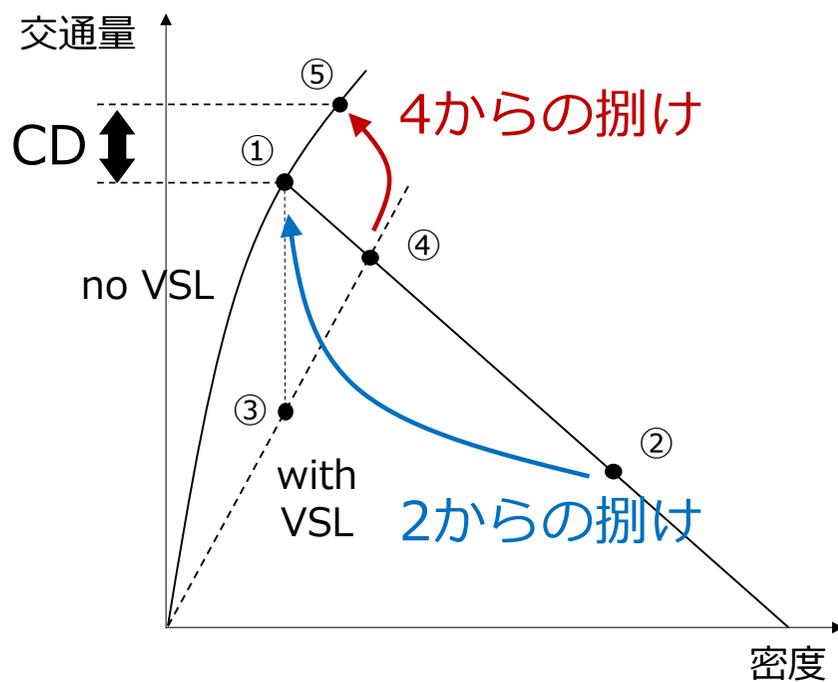


- 交通状況に応じて自動的に制限速度を変更
- 1960年代ドイツのSpeed Harmonnization～



可変制限速度によるキャパシティドロップの回避

- Hegyi et al. (2008)



研究の目的

- ミクロ交通流シミュレーションを深層強化学習環境として用いることによって、コネクティッド自動運転車両(Connected Autonomous Vehicles、以降CAV)を考慮
- 速度変動による追突リスクを抑えつつ、と旅行時間を抑えられる可変制限速度システムを構築

Action policy : 制限速度の調整 ▶ 最善策を探索



01 平均旅行時間

路線全体の平均旅行時間を短縮することが目的
→平均旅行時間(秒)を直接、報酬値とする



02 PICUD (Possibility Index for Collision with Urgent Deceleration)

前方車両の急減速に反応し停止した時の車間距離
PICUD値0以下：衝突リスクが高い
→路線内の最小PICUD値 < 0 の時、平均旅行時間 $\times 2$



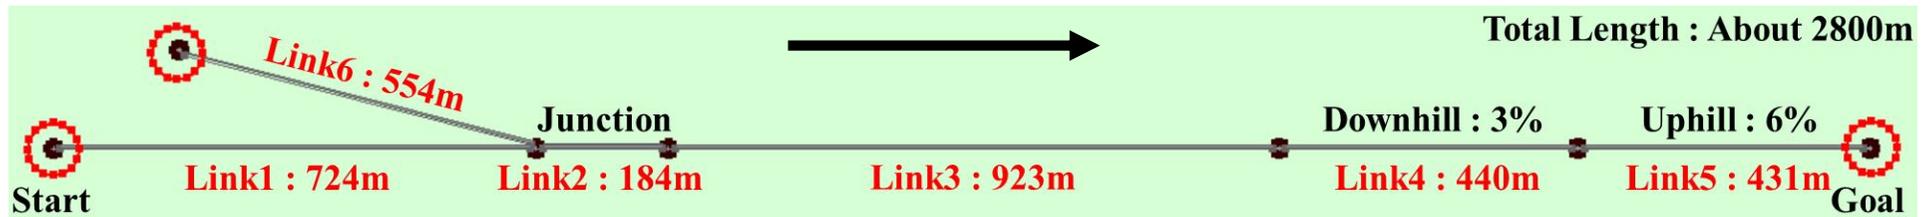
最小PICUD値が負にならないという制約条件のもと、交通状態に応じて平均旅行時間を最小化させるように制限速度制御モデルの学習を行う

環境 (Environment) の設定

- ミクロ交通流シミュレーション「MicroAVENUE」
 - 非線形追従挙動モデル「IDM+」を用いたシミュレーション
 - 勾配の影響を考慮
 - 合流・サグのある片側1車線区間を想定
 - Link 1~5でそれぞれ独立に制限速度を制御

$$\frac{dv}{dt} = a \cdot \min \left[1 - \left(\frac{v}{v_d} \right)^\delta, 1 - \left(\frac{s^*}{s} \right)^2 \right]$$

$$s^* = s_0 + vT + \frac{v\Delta v}{2\sqrt{ab}}$$



交通量設定

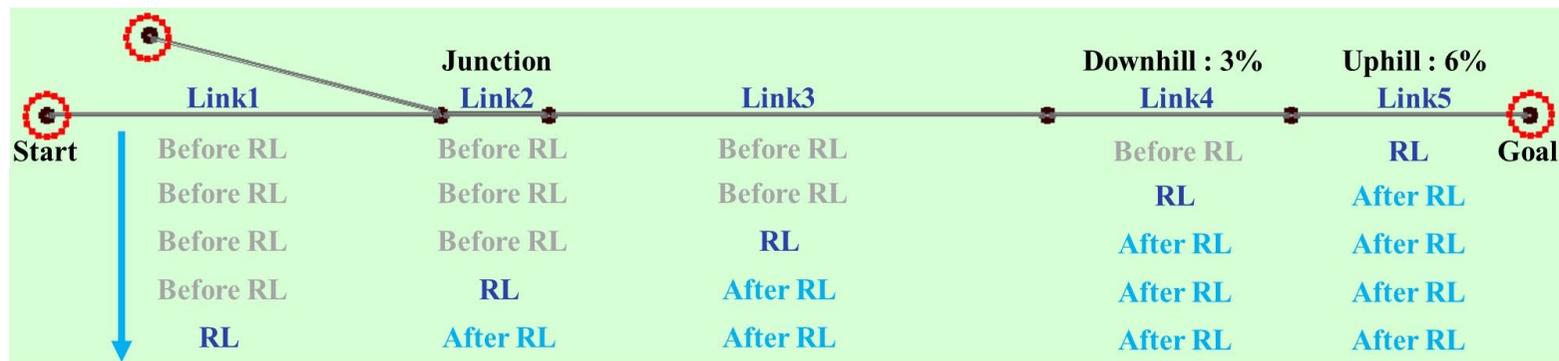
本線交通量 (台/40分)		合流交通量 (台/40分)	
小型車	大型車	小型車	大型車
300	100	120	40

状態 (State) ・ 行動 (Action) の設定

- State: 交通密度
 - 1: 0~20 veh/km
 - 2: 20~40 veh/km
 - 3: 40~60 veh/km
 - 4: 60~80 veh/km
 - 5: 80 veh/km ~
- Action: 制限速度の変更
(初期値は全リンク80km/h)
 - 0: Down (5km/h減)
 - 1: Stay (変更なし)
 - 2: Up (5km/h増)

30秒ごとに更新

- 下流側リンクから順に学習



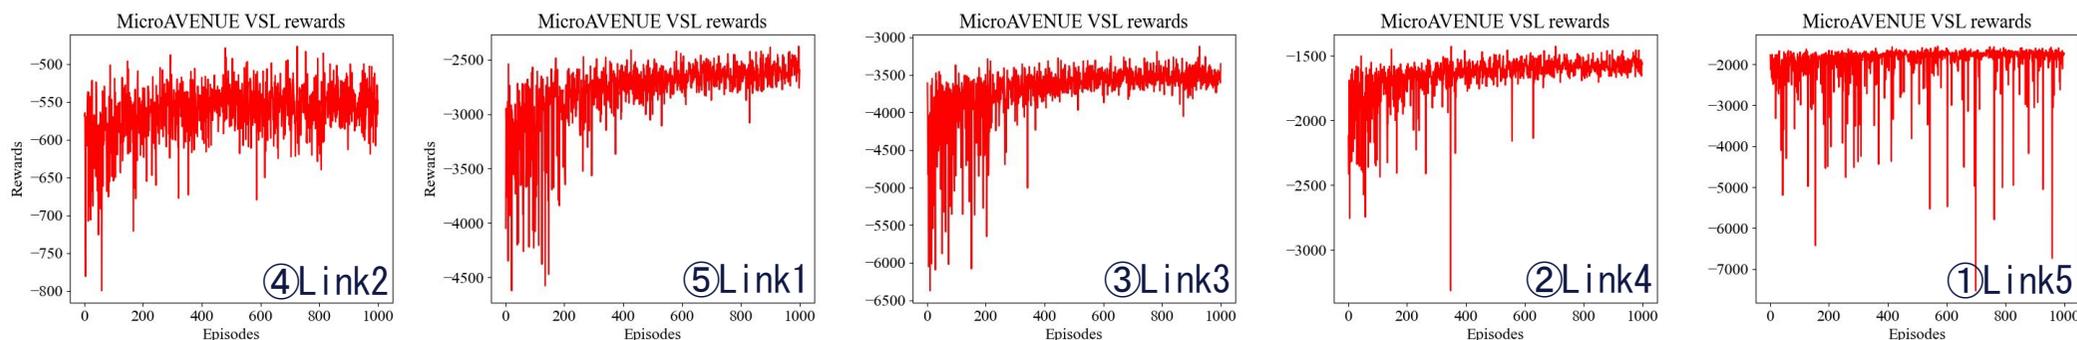
深層強化学習の枠組み

- PyTorchによる実装

項目	説明	設定値
total_episodes	エピソード数 (MicroAVENUEの実行回数)	1000 (×5区間)
num_layers	モデルの隠れ層の数	4
width_layers	各隠れ層のニューロンの数	400
batch_size	一度にモデルに提供される学習データのサンプル数	64
lr	学習率	0.001
training_epochs	学習のエポック数	800
fc1_dims、fc2_dims、 fc3_dims	ニューラルネットワークの1層目、2層目、3層目の次元数	1024、512、256
tau	ターゲットネットワークの更新に使用するパラメータ値	0.001
min_mem_size	リプレイメモリの最小サイズ	600
max_mem_size	リプレイメモリの最大サイズ	100000
num_states	状態の数	2 (交通密度, 制限速度)
num_actions	行動の数	3 (制限速度-5, 0, +5)
gamma	割引率	0.95
epsilon	ϵ -greedy法における初期の ϵ 値	1.0
epsilon_end	ϵ -greedy法における ϵ の最終値	0.01
eps_dec	ϵ の減少率	0.0005

結果：交通需要が低い場合

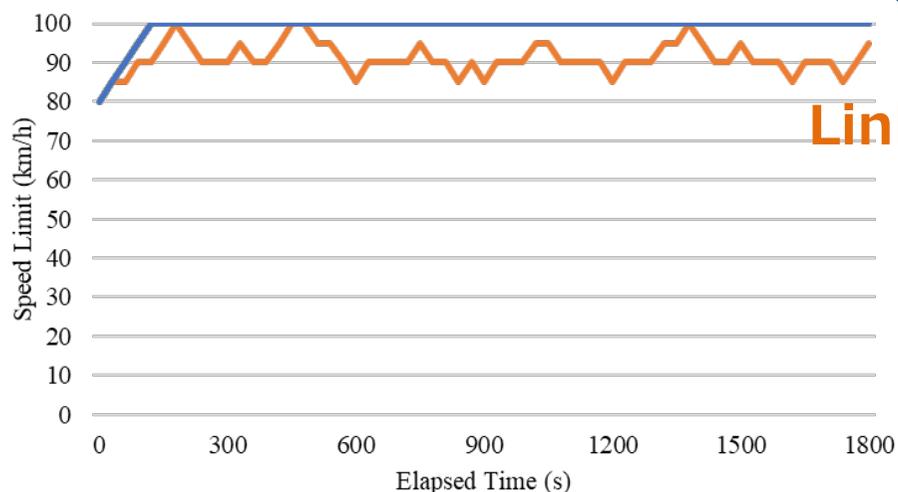
- 総報酬の推移
 - 下流区間が学習モデルで安定した交通状態となり、上流区間での学習効率が向上



結果：デフォルトケース

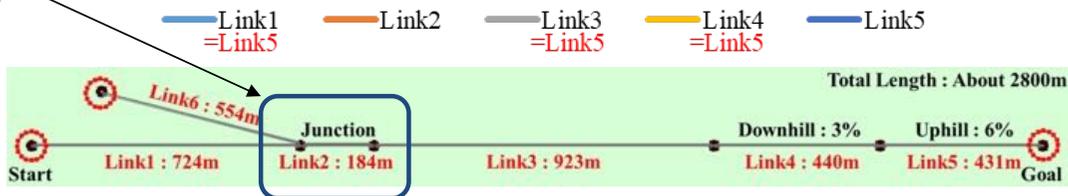
- 学習モデルによる制限速度の変化
 - Link2：交通密度の大きさに合わせて80km/h以上で変動し続けた
 - その他：上限の100km/hまで制限速度を引き上げた

その他区間



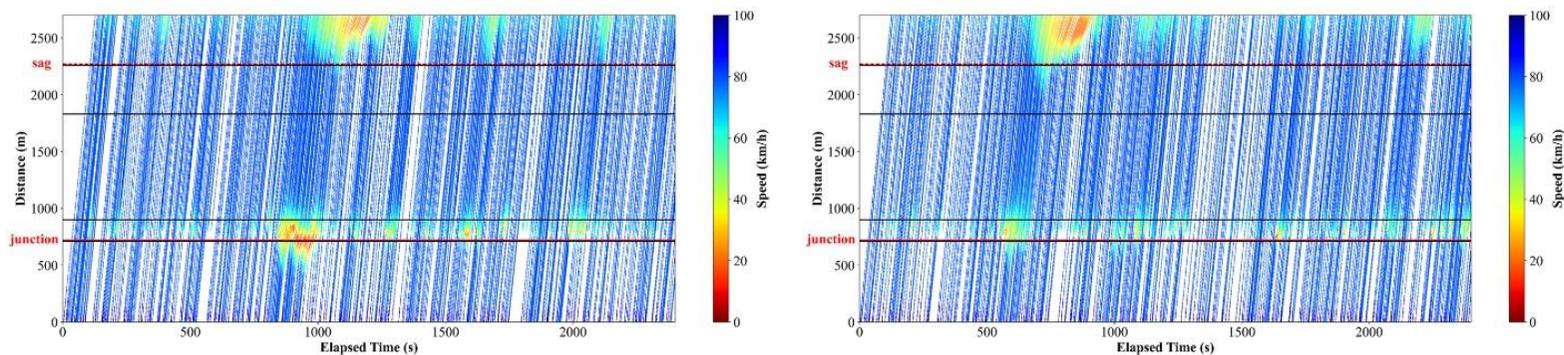
Link2 (合流区間)

Link2 (合流区間)

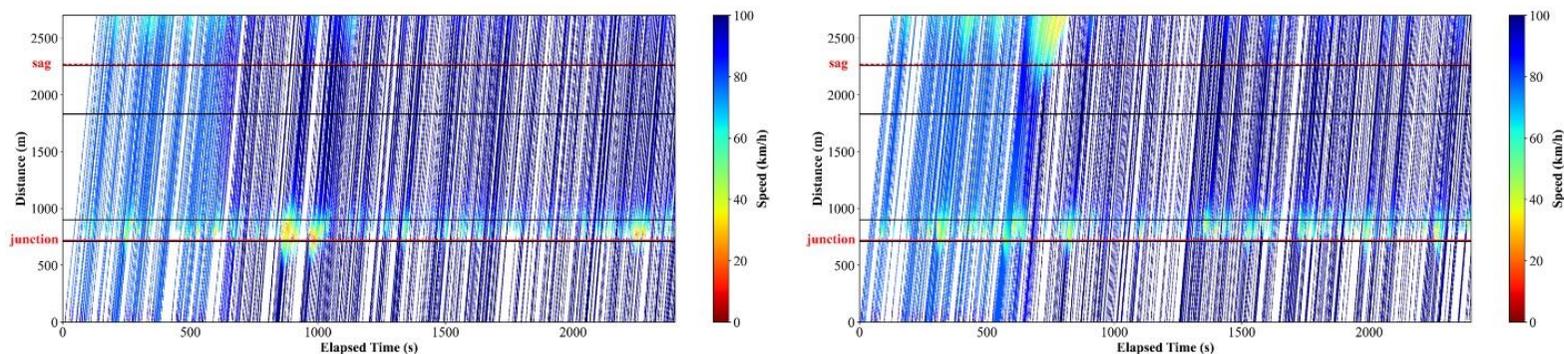


結果：デフォルトケース

- 学習前：50回試行の平均旅行時間 115.23秒

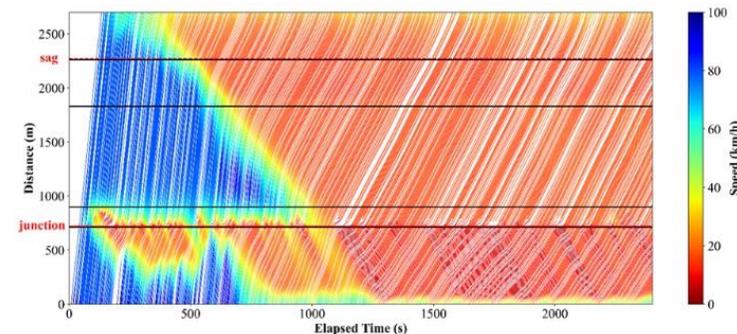
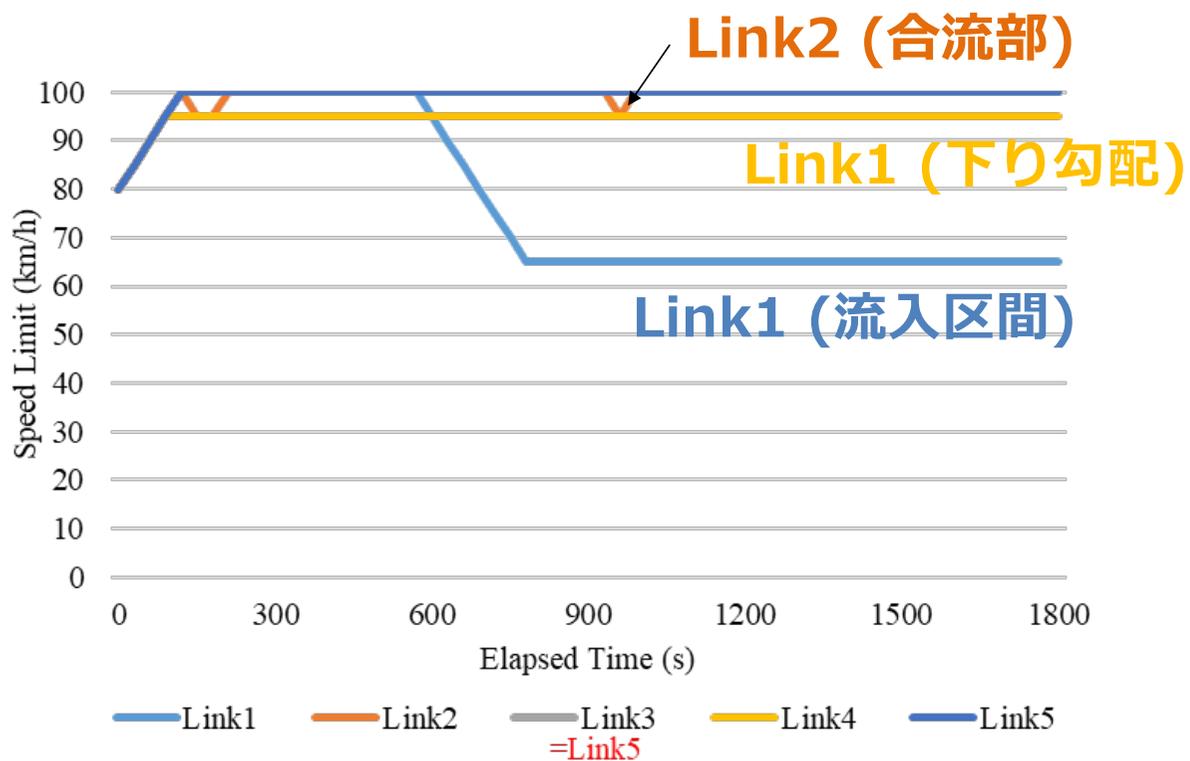


- 学習後：50回試行の平均旅行時間 94.90秒



結果：交通需要を2倍に設定

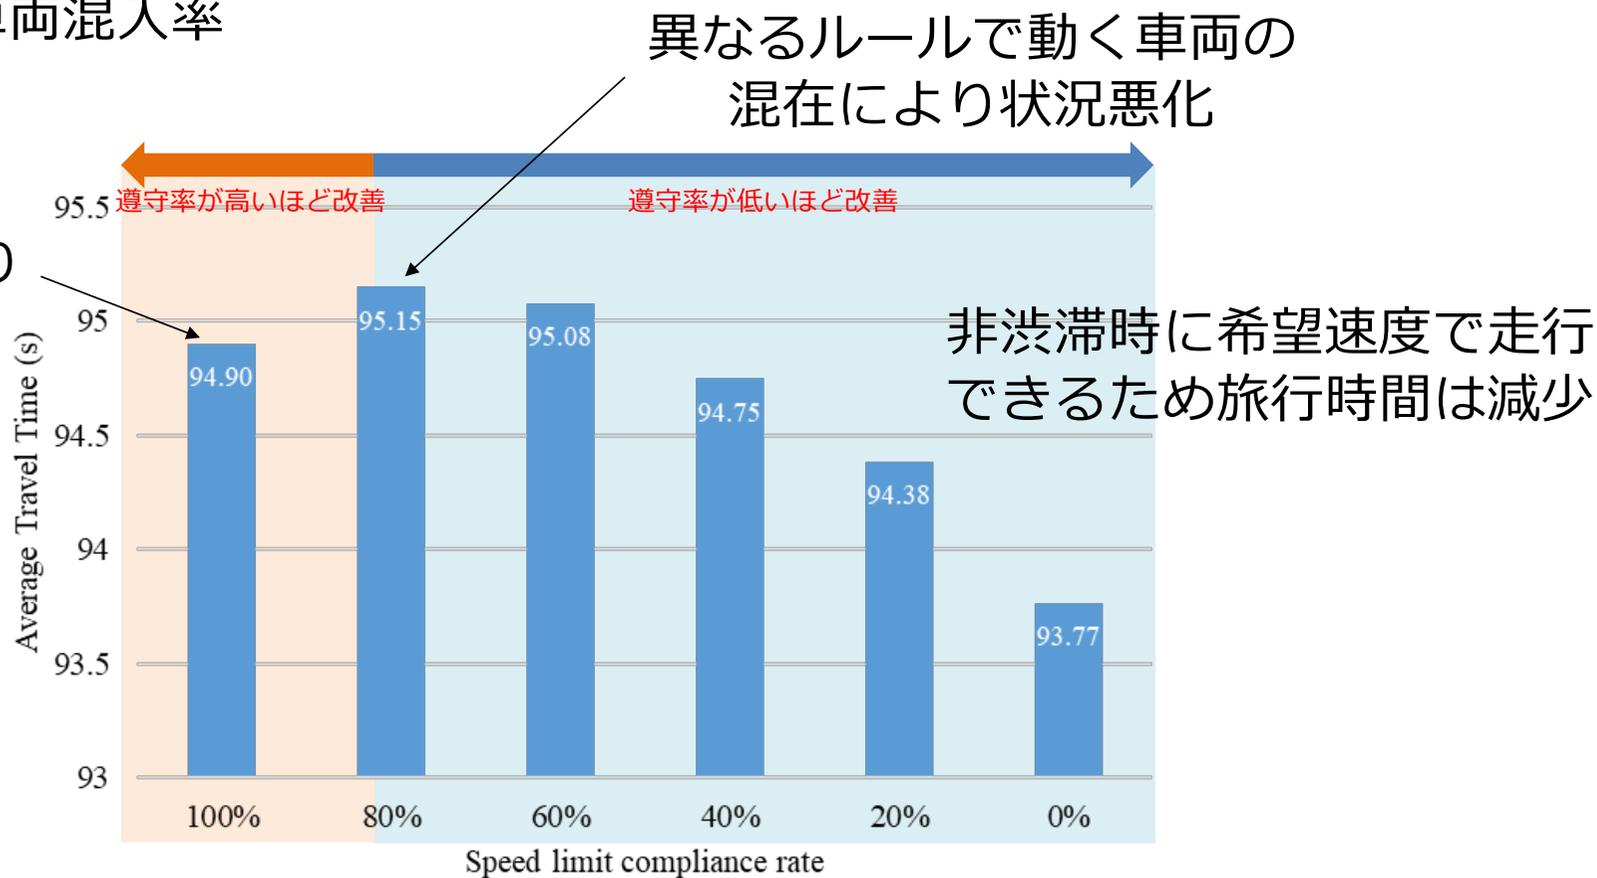
- 学習モデルによる制限速度の変化



遵守率の影響

- CAV車両 = 必ず制限速度を守ると過程
- 遵守率 = CAV車両混入率

均質性の向上により
交通状況は改善



まとめ

- 下流区間から学習を行うことで下流の交通状態が安定し、学習効率が向上する
- 交通工学的に解釈可能な制限速度制御を学習
- CAVが普及していき、制限速度遵守率が高い状態となった時に本システムの交通流改善効果が発揮される

- マルチエージェント学習
- 多車線区間への適用（計算時間の増加がネック）
- 他のATMメニューとの融合

さいごに

- 交通流の観測・データと理論は両輪
- 現象とそのメカニズムへの理解があって、有効な制御が可能
- 理想と現実にはギャップ（「取り締まり」が最後のピース）
 - Variable advisory speed limit vs Variable mandatory speed limit
- ACCだけでも渋滞は大きく改善するが、短い車間への受容性がキー
 - トータルとしての自動化が必要
- 今後の自動運転の普及は、高速道路での専用車線から拡大？

ご清聴ありがとうございました

塩見 康博

shiomi@fc.ritsumei.ac.jp