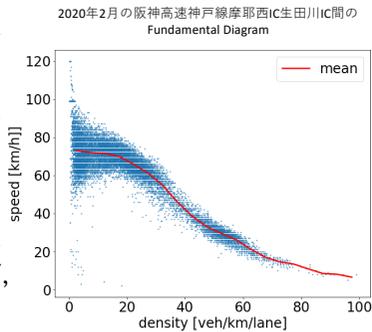


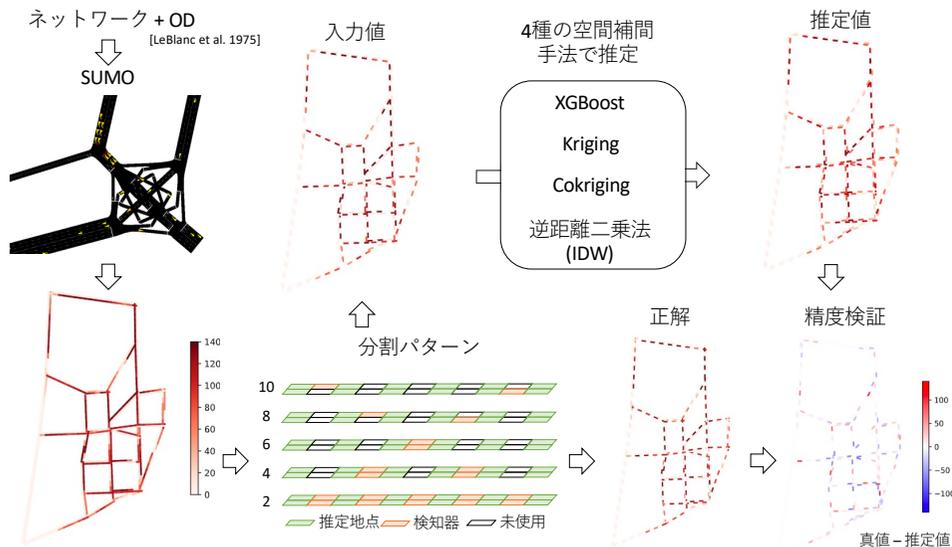
1. はじめに

- 道路ネットワークの交通状態予測に機械学習を用いた研究が活発に行われているが、そのほとんどで入力変数として速度が用いられている
- 特に自由流領域では速度は変動が小さく分散が大きいため、速度の代わりに空間補間された交通密度入力とすることで機械学習による交通状態予測精度が高まることが示唆されている [Katayama et al. 2022]
- 本研究では、シミュレーションにより生成した真の交通状態を用いた密度補間手法の比較検討及び、真の密度と補間密度を入力とした場合の機械学習による予測精度の比較検証を行った



2. 方法論

- Sioux Fallsネットワーク上にミクロ交通シミュレーションSUMOで生成した交通状態を真値とし、複数の空間補間手法で推定した密度の精度を比較した。



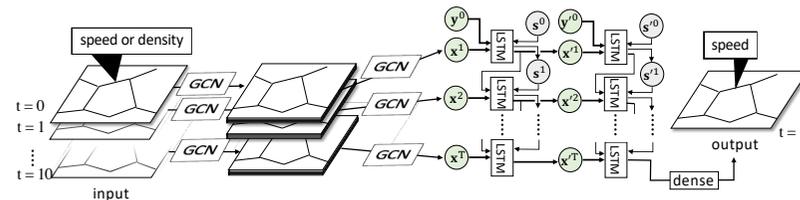
■ 検証結果

精度指標	逆距離加重法	Cokriging	Kriging	XGBoost
MAE [台/km/車線]	1.9176	1.8687	1.9128	2.0939
RMSE [台/km/車線]	6.2253	5.9997	6.0466	6.3330
計算時間 ^{*)} [sec]	0.019	0.601	0.582	1.980

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

3. ケーススタディ

- 推定した密度、速度、真の密度をそれぞれ入力として機械学習手法により速度を予測し、その精度を評価した。
- 予測にはGraph Convolutional Network (GCN)とLong Short Term Memory (LSTM)の複合モデル(下図)を用いた



■ 検証条件

- 1タイムステップ：5分
- 期間：30日間
- 検証地点：288地点
- 入力：過去150分の速度or密度
- 出力：1時間後の速度
- 交差検証：4分割交差検証

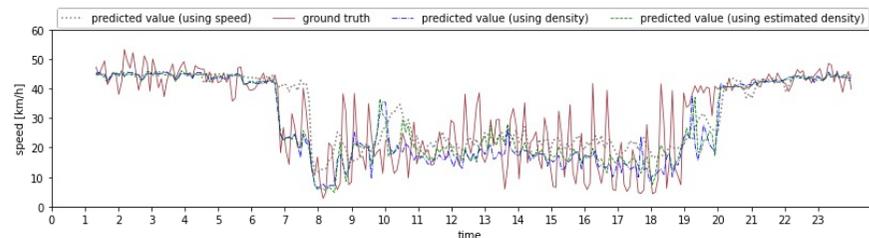
■ 予測結果

metrics	density (true)	density (interpolated)	speed
MAE	2.2164	2.2107	2.2753
MAPE	3.3421	3.3370	3.4333
RMSE	3.9937	4.0076	4.2902

評価指標

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

■ 予測値と真値の比較



4. 考察とまとめ

- 速度を入力とした場合は渋滞の発生を事前に予測できていないが、密度を入力とした場合は補間した密度であっても真の密度と同様に事前に予測できており、単純な補間手法であっても密度を入力とした方が速度を入力とした場合よりも交通状態の予測精度が高まることが示唆された。
- 単純な空間補間手法により推定した密度を入力とした場合でも、真の密度を入力とした場合と同程度の予測精度が得られた。