

短時間速度予測における Gradient Boosting Decision Tree と Graph Neural Network の比較

緒方 陸¹・宮崎 利行²・菊池 恵和²・村野 祐太郎³・菅原 宏明²

¹非会員 八千代エンジニアリング株式会社 (〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー)
E-mail: rk-ogata@yachiyo-eng.co.jp (Corresponding Author)

²正会員 八千代エンジニアリング株式会社 (〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー)

³非会員 八千代エンジニアリング株式会社 (〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー)

主要地点でデジタルツインを構築することで、渋滞発生回避などを目的としたリアルタイムの交通流予測や動的な交通制御が可能となる。本稿では上記活用を見据え、オープンデータであるイングランドのデータを用いて短時間速度予測を実施した。モデルには Gradient Boosting Decision Tree (GBDT) と Graph Neural Network (GNN) を使い、両者の比較を実施した。対象 170 地点全体の比較結果からは GNN 優位であるものの、個別地点ごとの評価では GBDT 優位の地点も複数存在することを明らかにした。また、時刻が大きく寄与する地点では GNN 優位を確認し、これらの地点に対して GNN の隣接行列から有効と判断した他地点データを GBDT 入力データに追加することにより、GBDT 精度向上に寄与することを確認した。最後に、GBDT と GNN の使い分けについて論じた。

Key Words: traffic prediction, gradient boosting decision tree, graph neural network, open data

1. はじめに

道路施策検討や現場管理等への活用のほか、一部データを民間開放することでオープンイノベーションを促進するべく、国土交通省は xROAD の構築を進めている。道路施設の位置や完成年度、点検判定区分などの情報を登録した基礎データベース部分は本年 5 月に無料公開されており、将来的には ETC 2.0 プローブ情報や交通量を含む道路データが API としてリアルタイムで公開される予定である¹⁾。

ETC 2.0 プローブ情報や交通量などのデータ整備が進めば、渋滞が予想される道路区間の速度規制や、上流の交通量調整などが可能となる。このほか、民間のプローブデータや定点観測カメラによる交通量計測データ²⁾、株式会社 NTT ドコモのモバイル空間統計³⁾データ等も活用が進むことで、交通流予測や渋滞要因分析などにおいて、より精緻な分析が可能となる。

主要地点においては、デジタルツインを構築し、リアルタイムに交通流等を予測することで、この結果を基に柔軟かつ動的な交通制御ができる。上記を支える技術として交通流予測があり、これにより渋滞発生回避や渋滞に伴う損失を軽減できる可能性がある。

宮崎らは xROAD によるデータ公開を見据え、交通量

データの活用法を検討する中でイングランドの交通データが一般に公開されていることに着目し、このデータを用いて渋滞予測を試行した⁴⁾。また、近年ではグラフ構造により空間的な特徴量を獲得する Graph Neural Network (GNN) を用いた手法も多く開発され、各種ベンチマークデータセットで最高精度を発揮している^{5,6,7)}。

本稿では、宮崎ら⁴⁾と同様に、イングランドのオープンデータを用い、Gradient Boosting Decision Tree (GBDT) や GNN を用いて交通流予測を実施し、両モデルの比較を行った。GNN を用いた交通流予測の各種ベンチマークデータセット評価では、個別の地点ごとの評価が行われていない。そのため本稿では、地点による GBDT と GNN の精度の違いを明らかにすることを目的とし、最後に GBDT と GNN の使い分けについて論じた。

2. 既往研究

過去には GBDT を用いて交通状況や交通流を予測した例がある。

宮崎らは GBDT の一つである LightGBM を用い、平均速度や平均台数から渋滞か否かの分類を実施した⁴⁾。対象とした地点は 1 地点 (順方向/逆方向) のみであった

が、その方向によっても精度が異なった。また宮崎らは、モデルの性能は地点により異なると考え、汎化性が課題としている。

また、深層学習手法を用いた例として、多変量データに LSTM を適用し交通量を予測した例⁸⁾や、CNNにより渋滞発生を予測した例などがある⁹⁾。これらもある地点のみを対象としており、モデルの汎化性については言及していない。

最近では、GNN を適用した研究も多く存在し、国内でも寺前らが阪神高速道路を対象に 10 分後の渋滞発生予測を実施している¹⁰⁾。また海外では、カリフォルニア州の交通データである METR-LA や PEMS-BAY¹¹⁾など各種ベンチマークデータセットにおいて、GNN を適用した手法が高い精度を発揮している^{5,6,7)}。ただし、評価指標は地域全体の複数地点をまとめて評価した値が用いられている。実際には商業施設や観光施設、大学、工場等周囲の環境などの要因により、交通流の特性は異なり、これに伴い精度も地点ごとに異なると考えた。

以上から、本稿では次の四つの検討を実施した。一点目は、GBDT と GNN の精度比較を行い、手法の有用性を確認した。二点目には、GBDT および GNN の地点ごとの精度比較を実施し、その特性を明らかにした。さらに、GBDT よりも GNN が精度を発揮した地点において、GNN の結果を踏まえて GBDT 精度向上の可能性を示した。最後に、上記検討結果を踏まえ、GBDT と GNN の使い分けについて議論した。

3. 実験概要

(1) データセット

宮崎らが使用した「WebTRIS Traffic Flow API」¹²⁾よりダウンロードしたイングランドのデータを用いた。収集したデータは全国 15,743 地点分存在するが、データのアクティブ状況や欠損状況等を踏まえ、図 1 のフローに基づき検討対象地点選定を行った。なお、平均速度 (Avg mph) の 75 パーセンタイル値と 25 パーセンタイル値の差分が大きい地点は便宜的に渋滞が発生しているとみなした。図 1 のフローにより、渋滞発生時のデータが多い地域として Birmingham 周辺地域と London 西部地域が選定されたが、London 西部地域は M25 道路上以外にデータが少なく空間的な広がりがない。本研究では将来的に広範囲の交通流予測も見据えているため、空間的な広がりのある Birmingham 周辺地域を検討対象とし、最終的に Birmingham Town Hall から半径 30km 以内の範囲に位置する計 170 地点を検討対象地点とした (図 2 および表 1)。

新型コロナウイルスが交通状況に影響を与えた可能性を考慮し、使用したデータ期間は 2016 年 1 月 1 日から

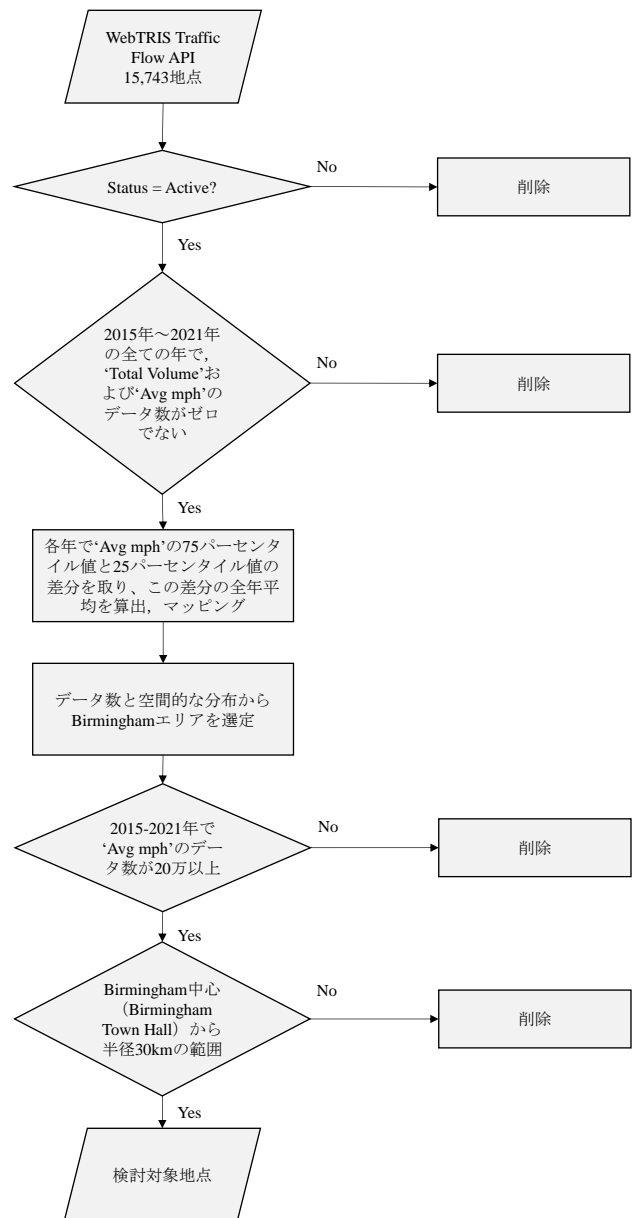


図 1 検討対象地点選定フロー

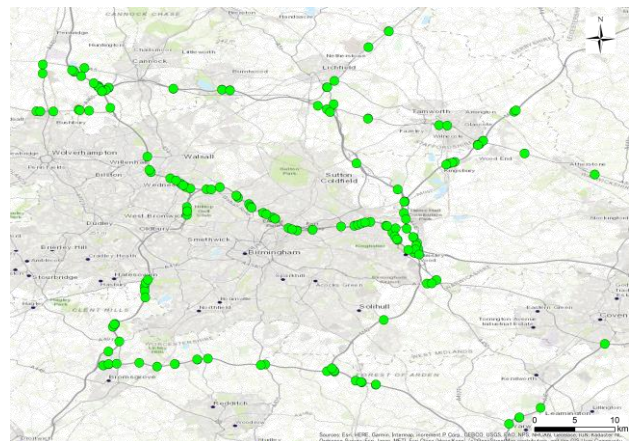


図 2 検討対象地点

表1 検討対象地点 (全170地点)

Id	Longitude	Latitude	Id	Longitude	Latitude	Id	Longitude	Latitude	Id	Longitude	Latitude
48	-1.9841	52.3557	2700	-1.7255	52.5177	5042	-1.6024	52.6393	9228	-2.0582	52.6646
175	-1.7168	52.4972	2709	-1.5986	52.2960	5088	-1.8878	52.3544	9229	-2.0582	52.6647
270	-1.8752	52.5198	2727	-1.6710	52.5817	5131	-1.6452	52.6004	9234	-1.9314	52.6625
513	-1.8717	52.5181	2899	-2.0169	52.4467	5294	-1.7753	52.5127	9235	-1.9314	52.6624
535	-1.7406	52.5027	2951	-1.7148	52.4838	5297	-1.7357	52.4952	9236	-1.9225	52.6618
561	-1.7131	52.4908	2953	-1.7831	52.5103	5468	-1.9842	52.3555	9237	-1.9225	52.6615
727	-1.9706	52.5311	2987	-2.0905	52.6396	5517	-1.7759	52.3357	9240	-1.8242	52.6444
1011	-1.9706	52.5224	3103	-1.7175	52.4978	5531	-1.8474	52.5049	9242	-1.8141	52.6404
1025	-2.0643	52.3540	3125	-1.8475	52.5051	5596	-1.8530	52.5062	9243	-1.8103	52.6373
1028	-1.8301	52.5059	3184	-1.7748	52.3350	5667	-1.7269	52.5372	9246	-1.7809	52.5800
1076	-2.0180	52.4421	3299	-1.8853	52.5248	5703	-1.8719	52.5180	9250	-1.7349	52.5509
1102	-1.7117	52.4844	3580	-1.8299	52.5058	5709	-1.9592	52.3608	9255	-2.0618	52.6618
1132	-1.7653	52.5146	3708	-1.8818	52.5232	5744	-1.7467	52.5099	9256	-2.0615	52.6618
1170	-1.9013	52.5344	3728	-1.6738	52.5809	5755	-2.0143	52.4499	9273	-1.7675	52.7100
1174	-1.5987	52.2959	3753	-1.9771	52.5572	5830	-1.9471	52.3618	9274	-1.7676	52.7100
1346	-1.9705	52.5265	3760	-1.7818	52.3371	5833	-1.7712	52.5139	9485	-1.7680	52.6301
1406	-2.0534	52.3973	3837	-1.7592	52.3326	5911	-1.9892	52.5633	9486	-1.7681	52.6300
1415	-1.8054	52.3472	3890	-1.7248	52.5070	5951	-1.9750	52.5555	9490	-1.7019	52.4457
1457	-2.0109	52.5702	3974	-1.8139	52.3476	6005	-2.0586	52.3696	9491	-1.6966	52.4458
1493	-1.9133	52.5418	3985	-1.9590	52.3606	6153	-1.6806	52.5787	9523	-2.0853	52.6867
1608	-1.7156	52.4798	3988	-1.7834	52.5101	6158	-1.9703	52.5265	9524	-2.0853	52.6866
1633	-1.7272	52.5374	4058	-2.0041	52.3529	6293	-1.9829	52.5609	9525	-1.9859	52.6635
1698	-1.6045	52.6376	4153	-1.8059	52.3481	6932	-2.0172	52.4300	9526	-1.9859	52.6635
1712	-1.8569	52.5076	4238	-1.7481	52.5104	8272	-1.8064	52.6462	9689	-2.0462	52.3810
1725	-1.6778	52.5799	4384	-1.8085	52.3510	8275	-1.7449	52.7277	9980	-2.1200	52.6380
1740	-1.9337	52.5533	4396	-1.6393	52.6054	8276	-1.7447	52.7276	10354	-2.0695	52.6663
1747	-1.7348	52.4944	4402	-1.7981	52.5093	8289	-2.1321	52.6806	10372	-2.0661	52.6605
1784	-2.0509	52.4005	4403	-1.7106	52.4782	8290	-2.1318	52.6905	10373	-1.7230	52.4834
1828	-1.9719	52.5535	4438	-1.8996	52.5320	8296	-1.5030	52.3781	10393	-2.0675	52.6638
1926	-1.7142	52.4883	4445	-2.0149	52.5876	8305	-1.6102	52.2888	10437	-1.7503	52.4049
2011	-1.7372	52.5075	4458	-1.7379	52.4985	8309	-1.5748	52.3066	10449	-2.0703	52.6661
2034	-2.0177	52.4375	4463	-1.8982	52.5304	8405	-1.5142	52.5677	10457	-2.1390	52.6383
2171	-1.9487	52.5511	4600	-2.0582	52.3554	8406	-1.5142	52.5677	10499	-2.0688	52.6645
2279	-2.0918	52.6400	4603	-2.0582	52.3555	8407	-1.5929	52.5911	10504	-2.0564	52.6421
2295	-2.0240	52.3570	4611	-1.7792	52.5114	8408	-1.5929	52.5912	10537	-2.0656	52.6606
2304	-1.9153	52.5440	4767	-2.0517	52.4002	8409	-1.6885	52.6226	10559	-2.0749	52.6696
2306	-1.6429	52.6015	4842	-1.6391	52.6053	8410	-1.6794	52.6223	10609	-2.0968	52.6825
2343	-2.0644	52.3541	4862	-1.7591	52.3328	8446	-1.8139	52.6652	10639	-2.1346	52.6380
2395	-1.8829	52.3552	4912	-1.9435	52.5509	8447	-1.8136	52.6651	10646	-2.0971	52.6827
2436	-1.7278	52.5247	4951	-2.0801	52.6390	8453	-1.7275	52.5372	10648	-2.0889	52.6776
2479	-1.9668	52.5518	4961	-2.0126	52.5728	8993	-1.8055	52.6722	10655	-2.0992	52.6841
2487	-1.6454	52.6005	4989	-2.0492	52.3560	9092	-1.6915	52.4496			
2660	-2.0536	52.3973	5038	-1.9154	52.5439	9093	-1.6912	52.4497			

2019年12月31日として学習データ, 検証データ, テストデータにはそれぞれ, 2016年および2017年, 2018年, 2019年を用いた. データは15分単位で整備されており, 平均速度と合計台数 (Total Volume) を用いた. データの欠損処理については, 15分から1時間連続で欠損している場合は線形補間を, それ以上欠損が続く場合には曜日・時刻ごとの中央値で補間した. なお, 入力データには現況から12時刻前まで (2時間45分前まで, 3時間分) の平均速度および合計台数と, 時刻 (15分単位時刻を正規化, 0~1) および曜日のダミー変数 (0~6) を用いた. ここで, GBDT は各地点ごとに学習・推論を行うため, 入力データも各地点ごとのデータを用い, 対象170地点の学習・推論を実施した. 一方GNNは全地点一括で学習・推論を行うため, 入力データには全地点のデータを用いた.

各モデルとも出力は1時刻から12時刻先 (15分先から180分先) の全12時刻分の平均速度とした.

(2) モデル

本稿ではGBDTとGNNを用い, 両モデルの比較を実施した. GBDTには宮崎ら⁴⁾が使用するLightGBMを用いた.

ここで, GBDTや時系列予測でよく用いられる深層学習手法のRNN系のモデルでは, 空間的な地点間の依存関係を考慮できていないことが課題とされていたが, 近年発展が著しい交通流分野のGNNでは地点間の関係をグラフ構造で捉えることで精度向上に繋がった⁵⁾. 交通流分野のGNNにはGraph Convolutional Networks (GCN)が良く用いられ, 隣接行列と入力・出力の関係は, 参考文献⁹⁾より以下の式で表される.

$$Z = \tilde{A}XW \quad (1)$$

ここで, $Z \in R^{N \times M}$ は出力, $\tilde{A} \in R^{N \times N}$ は隣接行列, $X \in R^{N \times D}$ は入力, $W \in R^{N \times M}$ はモデルのパラメータを表す. ここに, Graph WaveNet では隣接行列として, 以下で表す”self-adaptive adjacency matrix (\tilde{A}_{adp})”という方法を取り入れた⁹⁾.

$$\tilde{A}_{adp} = \text{SoftMax}(\text{ReLU}(E_1, E_2^T)) \quad (2)$$

$E_1 \in R^{N \times c}$ はソースノードに対し埋め込みを行ったベクトル, $E_2 \in R^{N \times c}$ はターゲットノードに対し埋め込みを行ったベクトルを表す. ReLU関数により弱い関係は除かれ, 各地点間の関係を表す数値はSoftMax関数により正規化される. これらの微分可能な関数を用いることで隣接行列の学習を可能とし, 空間に依存しない地点間の関係を取得できる構造としたことで高い精度を発揮した⁹⁾. 加えて, ”Gated TCN”と呼称するモジュールを組み込むことでより長期間の特徴を捉えることが可能となった.

本稿では, GNNの手法として, METR-LAやPEMS-

BAYなどのベンチマークデータセットで高い精度を発揮した, 上記に挙げるGraph WaveNetを用いた. ネットワーク等詳細についてはWuらの論文⁹⁾を参照されたい.

なお, LightGBMのハイパーパラメータ探索にはPythonライブラリのoptunaを用い, 地点ごとに最適なパラメータを調整した. Graph WaveNetのハイパーパラメータはデフォルトとし, エポック数は300とした.

(3) 評価指標

GBDTとGNNの全地点一律の比較においては, 地点ごとの数値大小の差による影響を受けない平均絶対誤差率 (MAPE) および決定係数 (R^2) を評価指標として用いた. 各指標の算出方法を以下に示す. \hat{y}_i は予測値, y_i は観測値, \bar{y} は観測値平均値, n はサンプル数を表す. また, 地点別の評価においては二乗平均平方根誤差 (RMSE) を用いた. ここで, 平均速度ゼロ, すなわち合計台数がゼロの時刻は渋滞が発生しにくい夜間に多い一方で, 評価指標に大きな影響を与える. 本検討は渋滞発生回避などへ活かす目的から, 評価においては平均速度ゼロの時刻を除いて評価を実施した.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{\bar{y}} \times 100 \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

4. 結果と考察

(1) GBDTとGNNの比較

結果を図3に示す. なお, 算出した評価指標は全地点の平均値を表している. MAPEは数値が低いほど精度が良く, R^2 は数値が高いほど精度が良い. 結果から, 全予測時刻においてGNNがGBDTよりも優れる結果となった. 今回用いたGNNのGraph WaveNetは, 地点の時空間的な依存関係を自動で効率的かつ効果的に取得できるため⁹⁾, これにより高い精度を発揮できたと推察した.

また, 時刻ごとにGNNが優位となる地点数の割合を算出した結果を図4に示す. 一貫してGNNの方がGBDTよりも精度が高い地点が多く, 特に30分先から90分先予測では8割を超える地点においてGNNの方が優位な結果となった. しかし, 60分先予測をピークにGNN優位となった地点数割合は予測時間とともに減少し, 180

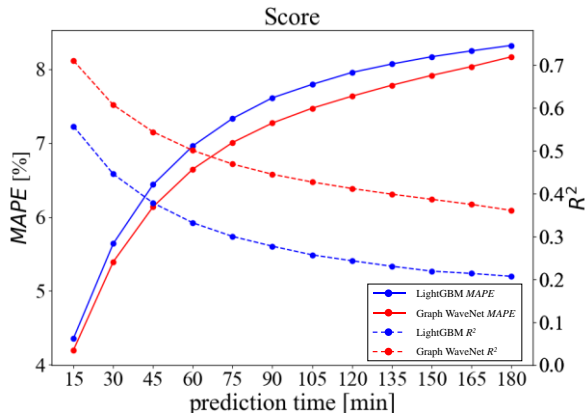


図3 GBDT (青線) と GNN (赤線) の精度比較 (MAPE (実線, 左軸), R² (点線, 右軸))




図4 GNNが優位となる地点数の割合

分先予測では6割を下回っている。長時間先の予測になるほど入力データのみからは有用な情報を捉えきれずに精度が低下し、モデルの違いによる影響が小さくなった(データによる影響が大きくなった)と推察した。

以上より、全地点一律の評価では GNN の精度が GBDT を上回っているものの、地点別に評価を行うと GBDT が GNN を上回る地点が存在する。用途・目的により使い分けは必要となるが、両手法とも有用であることを示した。次節では、上記の特性を明らかにすることを目的とし、検討を実施した。

(2) GBDT と GNN の地点による特性の違い

地点による比較を実施するため、RMSE による評価を行った(図5)。図は各時刻(12時刻分)における GNN の RMSE で評価した結果から GBDT の RMSE で評価した結果を差し引いた数値の平均値 $RMSE_{mean}$ を載せており、 $RMSE_{mean}$ の数値でソート(左から昇順)して示している。 $RMSE_{mean}$ を算出した式を以下に示す。 $RMSE_i^{GNN}$ および $RMSE_i^{ML}$ はそれぞれ GNN, GBDT による $i \times 15$ 分先予測結果の RMSE 評価値を表す。

$$RMSE_{mean} = \frac{1}{12} \sum_{i=1}^{12} (RMSE_i^{GNN} - RMSE_i^{ML}) \quad (6)$$

図より、GNN の方が高い精度を発揮している地点が多いものの、Id=1457 など複数地点で GBDT 優位な地点が存在する。ここで、図6は45分、90分、135分、180分各時刻の RMSE 差分をマッピングした図である。図からも地点により必ずしも GNN 優位でないことを確認でき、例えば M6 Toll 道路の地点では一貫して GNN が精度を発揮しているものの、M6 道路では時間とともに GBDT の精度が上回っている地点が存在する。本節ではこうした GBDT 優位/GNN 優位な地点に対し、SHapley Ad-ditive exPlanations (SHAP)¹³⁾による評価により、地点の特性を明らかにする。

式(6)で表した $RMSE_{mean}$ (図5の数値) が最も大きい5地点 (GBDT 優位地点) と最も小さい5地点 (GNN 優位地点) において、宮崎ら¹⁴⁾と同様に GBDT の説明変数重要度を SHAP 値により評価した(図7)。ここでは GBDT と GNN の特性の違いを明らかにするべく、極端な例として、GBDT に比べ GNN が最も精度を発揮した予測時刻(60分先予測)で評価した。図中縦軸の v_000~v_180 は現況~180分前平均速度、q_000~q_180 は現況~180分前合計台数、time_in_day は時刻、day_in_week は曜日を表す。図より、GNN 優位地点では時刻(time_in_day)の寄与度が大きい傾向にある。一方で




図5 GBDT と GNN の比較 ($RMSE_{mean}$) (青色: GBDT 優位, 赤色: GNN 優位)

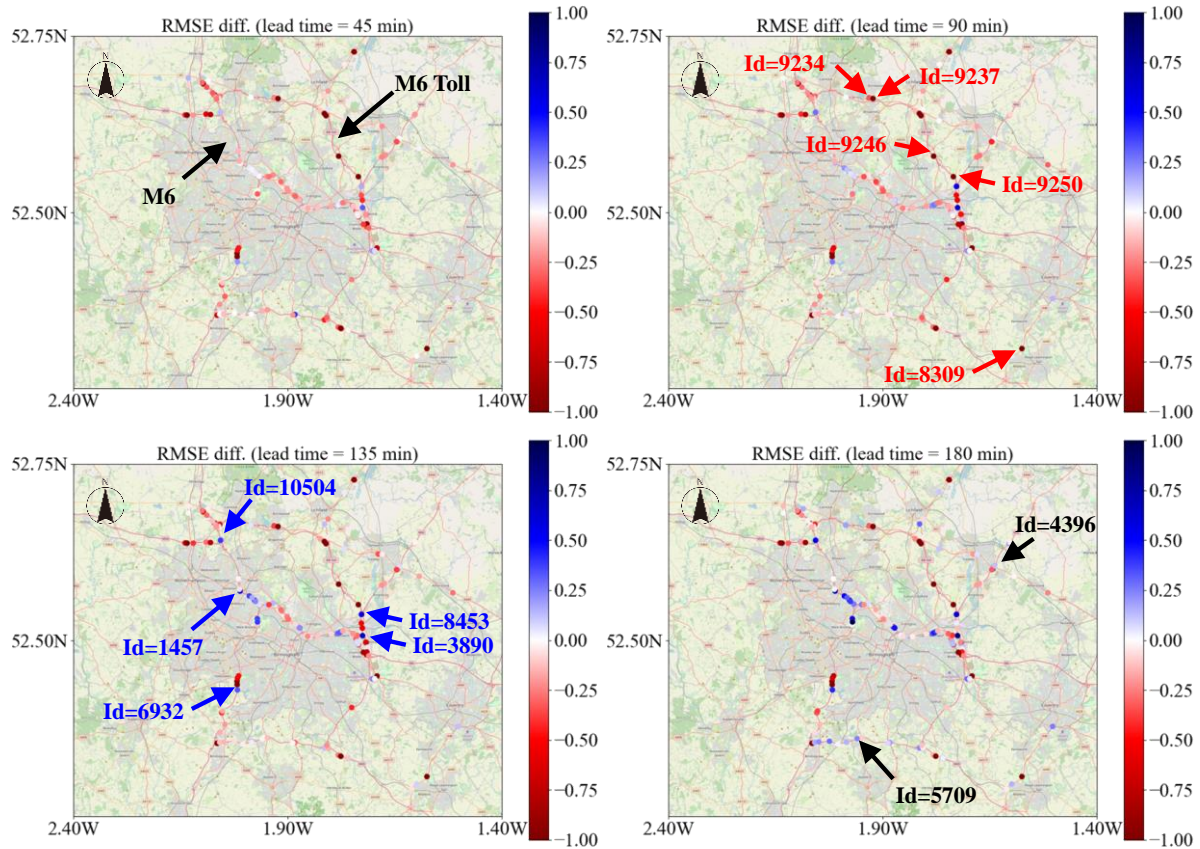


図6 地点別 GBDT と GNN の比較 (45, 90, 135, 180 分先予測, *RMSE* の差分)
(青色 : GBDT 優位, 赤色 : GNN 優位) (© OpenStreetMap contributors)

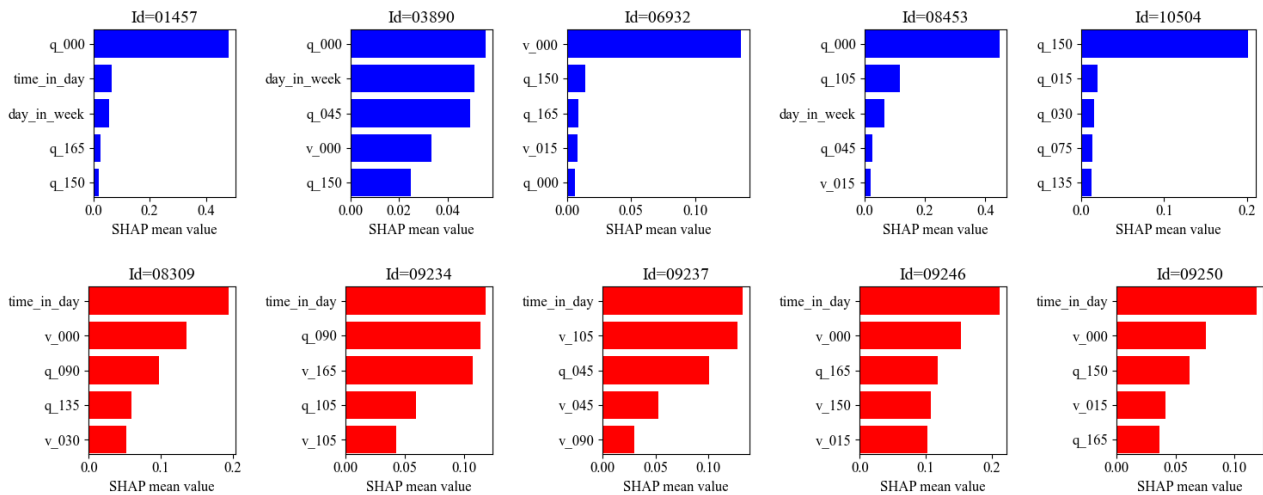


図7 60分先予測 SHAP 値絶対値 (縦軸: 変数名, 横軸 SHAP 値平均値)
(上段 : GBDT 優位地点, 下段 : GNN 優位地点)

GBDT 優位地点では現況の平均速度 (v_000) や合計台数 (q_000) など時刻以外の変数の影響が大きい。これは GNN 優位となった地点において、対象とする地点のみの情報 (GBDT の検討において用いた変数) からは予測の手掛かりとなる情報を得られないためと考えた。

以上より本節では、予測において対象とする地点の情

報 (平均速度や合計台数等) よりも時刻の影響が大きい地点においては GNN が精度を発揮できる可能性が高いことを示した。一方、対象とする地点の情報が大きく影響する場合には GBDT でも十分に高い精度で予測できる可能性があることを明らかにした。




図8 Graph WaveNet より得られた隣接行列 (抜粋)
(左図 : Id=8309, 右図 : Id=9250, 明色ほど横軸地点から縦軸への寄与が大きい)

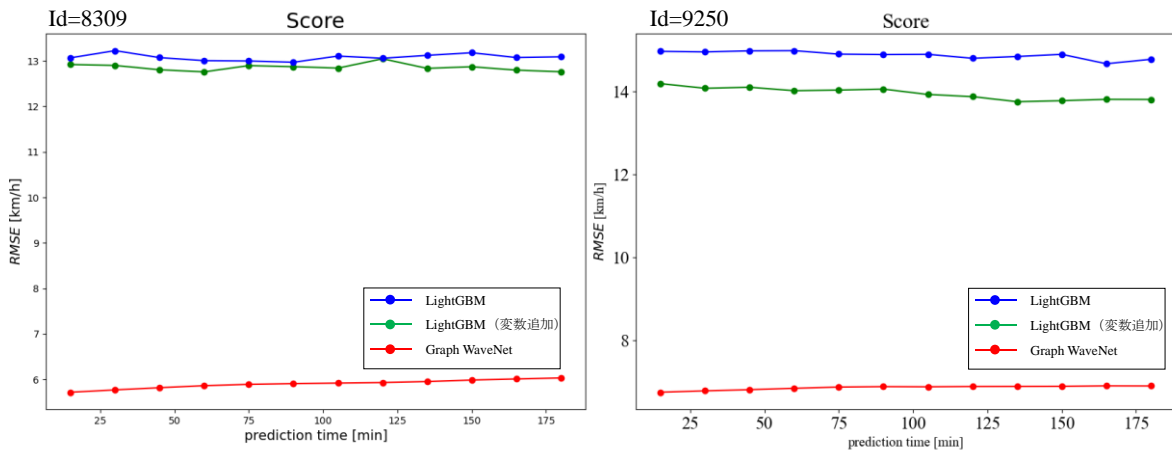


図9 GBDT 変数追加前後の比較 (左図 : Id=8309, 右図 : Id=9250)

(3) GNNの結果を踏まえたGBDT精度向上の可能性

本節では前節の結果を受け、GNN 優位の地点においてGBDT 精度向上の可能性について検討する。

前節では、GNN 優位の地点においてGBDT が精度を発揮できなかった原因として対象地点以外の地点の情報を考慮できていないことを挙げた。ここで、前述の通り、本稿で用いた Graph WaveNet は学習の中で自動的に地点間関係を取得できる。本節では Graph WaveNet の学習により得られた地点間関係を踏まえ、GBDT 精度向上の可能性について検討した。

Graph WaveNet の学習により得られた隣接行列のうち一部抜き出したものを図8に示す。明色ほど横軸地点による縦軸地点への寄与が大きい。Id=8309 を例にとると、Id=8309 への寄与は Id=4396 の影響が大きい。また、

同様に Id=9250 では Id=5709 の影響が大きい。これを踏まえ、それぞれ Id=8309 は Id=4396 の、Id=9250 は Id=5709 の平均台数および合計台数各 12 時刻分を入力変数に追加し、GBDT により学習・推論を行った。

変数追加前後およびGNNの Id=8309, Id=9250 予測結果を図9に示す。図より、全予測時間においてGNNには及ばないものの、変数追加前よりも追加後の結果が上回った。Graph WaveNet の隣接行列によると、両地点とも他の地点の影響を多く受けており、これに起因してGNNに及ばなかったと考えた。

前節の検討においては、GBDT では対象とする地点のみの情報からは予測の手掛かりとなる情報を得られなかった。しかし図9より、隣接行列から判断した寄与度の大きい地点の変数を追加することで予測性能が向上した。

これは前述の通り, Graph WaveNet により学習した地点間の関係を踏まえた変数追加によるものと考えた。

一方図 6 を見ると, Id=8309 と Id=4396, Id=9250 と Id=5709 はそれぞれ地理的には離れた地点に位置する。Graph WaveNet は接続されていない地点間の関係も捉えることから, 上で挙げた二地点間に関係があり, これらの変数を追加したことでGBDTにおいても二地点間の関係を捉えられるようになったことで精度が向上した可能性がある。しかし, これを明らかにするには交通工学的な観点による分析が必要であり, 今後の課題とする。

以上より, GBDT を使用した予測について, 対象地点のみの情報では予測が困難な地点においても関係性の高い地点の情報を取り込むことでより高い精度で予測できることを示した。

(4) GBDT と GNN の使い分けに関する議論

前節までの検討結果から, 本稿で示す限りにおいては, GNN は対象地点間の関係を捉え, 多数の地点において GBDT よりも精度良く予測を行うことができた。しかし, 一部の地点においては GBDT が GNN の性能を上回り, 高い精度を発揮した。

ここで, GBDT は特微量エンジニアリングに労力を要するものの, 対象地点が少数の場合には計算コストは小さい。一方, GNN は対象地点全地点を一つのモデルにより高い精度で予測が可能だが, 計算コストが大きい。参考までに, 本検討で実施した GBDT と GNN の比較を表 2 に示す。本稿では GBDT と GNN の学習・推論に異なるマシンを使用したため, 同じ基準での比較はできないが, GNN は計算コストが大きいことが分かる。一方 GBDT も少数地点であれば学習に多大な時間は要さないが, 地点数が多くなると計算コストは大きくなる。また, 前節で変数追加により精度向上の可能性を示したが, 追加する変数が増加するにつれ, 計算コストは大きくなる。

今回のように対象地点の周囲の環境や目的によっては, GBDT を選択する方が良い場合もある。例えば対象地点が少数であり, 対象地点と関係性の高い地点が明らかな場合には GNN を用いることは過分である。この場合, 計算コストの小さい GBDT やその他軽量のモデルを選択することが望ましい。

また, ある程度地点数やデータが大きい場合には, 両手法を併用することも可能である。本稿で用いた Graph WaveNet の”self-adaptive adjacency matrix”のように地点間の関係をデータから明らかにするモデルを使用すれば, この結果を基に説明変数を再考し, GBDT を適用する方法も有効であると考えられる。

以上のように, あるデータセットを対象に高い精度を

発揮する手法でも, 異なる地域を対象とした場合には精度を発揮できない可能性があるため, 技術者が目的やデータに応じて適切なモデルを選択し, 予測を行うことが重要であると結論付ける。

表 2 GBDT と GNN の比較

項目	GBDT	GNN
計算環境	CPU: 32 コア メモリ: 64 GiB GPU: 無	CPU: 16 コア メモリ: 64 GiB GPU: 有
学習時間	5分×170 地点	19時間
推論時間	3分	3分

5. おわりに

(1) 研究成果

本稿ではイングランドのオープンデータを用い, Gradient Boosting Decision Tree (GBDT) と GNN を適用して 15 分先から 180 分先の平均速度予測を実施, 両モデルの比較を行った。対象 170 地点全体の評価では GNN が優位な結果となったが, 個別に評価を行うと GBDT 優位の地点も複数存在した。

SHAP により地点ごとの説明変数重要度を確認すると, 時刻以外に対象地点のみのデータから予測の手掛かりを得られる場合には GBDT でも精度良く予測でき, 得られない場合(時刻の寄与が大きい場合)には GNN 優位となることを明らかにした。GNN 優位となった理由として, 本稿で用いた GNN の一つである Graph WaveNet は予測の手掛かりとなる他地点の情報を自動で取得できたことで精度向上に繋がったと考えた。

Graph WaveNet で学習した隣接行列を基に有効と判断した地点を選択し, GBDT の説明変数に選択した地点の情報も追加して学習・推論を行ったところ, GNN には及ばないものの, GBDT の精度向上に繋がった。以上から, GBDT の検討においても, 対象地点と関係性の高い地点の情報を追加することで精度が向上する可能性を示した。

最後に, 上記の結果から, ケースにより GBDT 優位な場合と GNN 優位な場合があることを確認したため, 両手法の使い分けについて議論した。技術者は目的やデータ, 計算資源等を考慮して GBDT と GNN, またはその他の手法を使い分けることが重要であると結論付けた。

(2) 今後の課題

本稿では Gradient Boosting Decision Tree (GBDT) に LightGBM を, GNN に Graph WaveNet を用いたが, GBDT や GNN には様々な手法がある。今回用いていない RNN

系の深層学習手法も時系列予測には多く用いられるため、これらを含めた検討が必要である。また、本研究では SHAP 値評価による説明変数重要度の観点で議論を行ったが、国内よりも情報を収集しにくいイングランドを対象としたこともあり、交通工学的な観点による地点間の特徴の違いを明らかにできていない。これを明らかにしていくことも、重要な検討事項として認識している。最後に、デジタルツイン構築に向け、xROAD や民間データの整備が進めば、将来的には日本国内を対象とした検討も必要になる。国内のさらなる交通予測の発展のためにも、重要な課題として今後検討していきたい。

参考文献

- 1) 国土交通省 道路局：道路施設の詳細な点検データの公開開始,
<https://www.mlit.go.jp/report/press/content/001490634.pdf> (2022/12/18 参照).
- 2) 小篠耕平, 菅原宏明, 藤井純一郎, 大久保順一, 岡野将大：路側からの撮影動画を用いた車種別車両計測とナンバープレート認識の複合認識システムの開発および流動分析への適用可能性検証, 交通工学研究発表会論文集, 41, pp.233-238, 2021.
- 3) NTT ドコモ：モバイル空間統計, <https://mobaku.jp/> (2022/12/19 参照).
- 4) 宮崎利行・大沢明瑠・菊池恵和・菅原宏明：イングランドの交通オープンデータと AutoML による短時間渋滞予測, AI・データサイエンス論文集, 3 巻 J2 号, pp.268-276, 2022.
- 5) Bing Yu, Haoteng Yin, Zhanxing Zhu: Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting, arXiv:1709.04875v4, 2018.
- 6) Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, Chengqi Zhang: Graph WaveNet for Deep Spatial-Temporal Graph Modeling, arXiv:1906.00121v1, 2019.
- 7) Renhe Jiang, Zhaonan Wang, Jiawei Yong, Puneet Jeph, Quanjun Chen, Yasumasa Kobayashi, Xuan Song, Shintaro Fukushima, Toyotaro Suzumura: Spatio-Temporal Meta-Graph Learning for Traffic Forecasting, arXiv:2211.14701v3, 2022.
- 8) 小川晃平・福田大輔：多変量 LSTM による短期交通量予測：鎌倉市の観光交通を対象として, 土木学会論文集 D3 (土木計画学), Vol.76, No.5 (土木計画学研究・論文集第 38 巻), I_1389-I_1398, 2021.
- 9) 坪田隆宏・砂侑奈・吉井稔雄：曇み込みニューラルネットワークによる都市間高速道路の渋滞発生予測モデル, 第 66 回土木計画学研究発表会・講演集, 2022.
- 10) 寺前智文, 向井理沙, 西海能史, 鈴木健太郎, 小島悠紀子, 廣田敦士, 幡山五郎, 影本義明, 櫻木伸也, 阿部敦：Graph Convolutional Networks を用いた阪神高速道路における交通渋滞発生予測, 第 18 回 ITS シンポジウム, 2020.
- 11) Yaguang Li, Rose Yu, Cyrus Shahabi, Yan Liu: Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting, arXiv:1707.01926, 2017.
- 12) highways england: WebTRIS Traffic Flow API, <https://webtris.highwaysengland.co.uk/api/swagger/ui/index> (2022/12/20 参照)
- 13) S. M. Lundberg, and Su-In Lee : A unified approach to interpreting model predictions, Advances in Neural Information Processing Systems, 2017.
- 14) 宮崎利行, 緒方陸, 村野祐太郎, 菊池恵和, 菅原宏明：イングランド一般道の AI による短時間速度予測, AI・データサイエンス論文集, (投稿中) .

(Received December 31, 2022)
(Accepted February 28, 2023)

COMPARISON OF GRADIENT BOOSTING DECISION TREE AND GRAPH NEURAL NETWORK FOR SHORT-TIME SPEED PREDICTION

Riku OGATA, Toshiyuki MIYAZAKI, Yoshikazu KIKUCHI, Yutaro MURANO, and Hiroaki SUGAWARA

By constructing a digital twin at key locations, real-time traffic flow forecasting and dynamic traffic control can be performed to avoid traffic congestion. In this paper, short-time speed prediction was conducted using open data from England in anticipation of the above applications. Gradient Boosting Decision Tree (GBDT) and Graph Neural Network (GNN) were used for the model, and a comparison was made between the two. The comparison results for the entire 170 target locations showed that the GNN was superior, but the evaluation of individual locations revealed that there were several locations where GBDT was superior. The results also confirmed the GNN was superior at the points where time contributed significantly, and confirmed that the addition of data from other points, which was judged to be valid based on the GNN adjacency matrix, contributed to improving the GBDT accuracy at these points. Finally, the use of GBDT and GNN is discussed.