

道路交通システムにおけるプローブ情報を用いた交通流予測手法の検討

A study on traffic flow prediction method using probe information in transportation system

大野啓介*¹
Keisuke OHNO

高屋英知*¹
Eichi TAKAYA

松本洋*²
Hiroshi MATSUMOTO

森田哲郎*²
Tesuo MORITA

栗原聡*¹
Satoshi KURIHARA

*¹慶應義塾大学 大学院理工学研究科
Graduate School of Science and Technology, Keio University

*²住友電気工業株式会社
Sumitomo Electric Industries, Ltd

With the remarkable development of Intelligent Transportation System in recent years, it is possible to easily collect traffic information and various information of the vehicle. Probe information provides more extensive traffic information in addition to the observation information. In this paper, we consider the traffic flow prediction method on urban road using probe information. Accurate and real-time traffic information is indispensable for the deployment of high-performance intelligent transportation systems. Traffic flow is complicated, but by deep learning that can acquire feature quantities automatically, it is possible to express the characteristics of the traffic flow without the prior knowledge such as the characteristics of the site, and it is expected to improve the prediction accuracy. Therefore, in this research, we consider a traffic flow prediction model using deep learning. Also, we compared it with other traffic flow prediction method.

1. はじめに

近年のITS(Intelligent Transport Systems:高度道路交通システム)の著しい発展により、道路交通情報や車両の様々な情報を容易に収集することが可能になっている。交通流を把握・予測するために収集される情報には、路上に設置されたセンサにより得られる観測情報と道路上を走行する車両から収集されるプローブ情報がある。プローブ情報によって、センサが設置された地点の観測情報より広範囲の道路交通情報が得られる。本研究では、プローブ情報を用いた交通流予測手法を検討する。高性能な高度道路交通システムの配備には正確でリアルタイムな道路交通情報が欠かせない。この情報によって、道路利用者がより良い経路判断をし、交通渋滞の緩和や排気ガスによる大気汚染の削減などにつながる可能性を秘めている。交通流予測の目的はこのような道路交通情報を提供するためである。これまでに、数多くの交通流予測モデルが提案されてきたが、扱う交通データの現場の特性を考慮したモデルがほとんどであり、この特性などの事前知識が必要である。近年、機械学習手法の一種である深層学習が学術的及び産業的に多くの関心を集めており [1], 画像認識や自然言語処理など様々なタスクにおいて深層学習の適用により精度が向上している [2][3][4][5]。交通流は複雑であるが、特徴量を自動的に獲得できる深層学習によって、現場の特性といった事前知識を把握していなくても交通流の特徴を表すことができ、交通流予測においても精度が向上すると期待される。

そこで、本研究では、プローブ情報を用いた深層学習による交通流予測手法を検討する。また、深層学習による交通流予測手法の妥当性を検証するために、従来の機械学習手法との比較を行う。

2. 関連研究

これまで提案されてきた予測手法では、扱うデータセットが観測情報かプローブ情報かに大きく分けられる。

連絡先: 慶應義塾大学 大学院理工学研究科 大野啓介
〒 223-8522 神奈川県横浜市港北区日吉 3-1-4-1
E-mail: k.o.lib65@gmail.com




図 1: DNN の構成

観測情報を用いた研究として、Yi ら [6] は深層学習である Stacked Auto Encoder(SAE) を用いて交通流の予測を行い、Support Vector Machine(SVM) などの従来の機械学習手法によるモデルより精度が上がることを示した。しかし、交通流の指標として車の台数のみを扱っており、正確な交通流を把握できない。本研究では、正確な交通流を把握するために、交差点間の通行にかかる時間であるリンク旅行時間を用いる。

プローブ情報を用いた研究として、Zheng ら [7] は隠れ層 1 層からなる Neural Network(NN) を用いてリンク旅行時間を予測している。この Zheng らの研究では、実験に使用するデータセットとして、シミュレーションにより得られたデータと 1 台のプローブカーより得られた情報を用いているが、現実的なデータセットではない。本研究ではこの点を考慮し、1 年間分のプローブ情報から得られるリンク旅行時間を用いた実験を行う。

3. 交通流予測

本研究での交通流予測手法では、図 1 のような Deep Neural Network(DNN) を用いる。入力をプローブ情報から得られる時刻 t 以前のリンク旅行時間とし、教師データである時刻 $t+\Delta$ のリンク旅行時間が出力となるように学習を行う。入力は予測




図 2: 道路リンクの一例

対象リンクを含めた時刻 t 以前の複数リンク、出力は予測対象リンクのみのリンク旅行時間とする。

4. 実験

前節で述べた予測手法でリンク旅行時間の予測を行う。また、その予測の妥当性を示すために重回帰分析及びサポートベクター回帰 (SVR) の予測精度と比較を行う。

4.1 使用するデータセット

使用するデータは、図 2 に示すような、岡山県の国道 2 号線付近 33 リンク分の 2016 年 6 月 1 日から 2017 年 5 月 31 日までの 1 年間のプローブ情報より得られたリンク旅行時間であり、リンク旅行時間は 5 分おきに平均されている。データの無い箇所は補完されており、リンク毎のプローブ情報の普及率は図 2 の楕円で囲われた数字で示しており、補完割合は約 70% から 99% である。

4.2 実験設定

本研究では 20 分後のリンク旅行時間の予測を行うので、DNN の出力は時刻 $t+4$ の予測対象リンクのリンク旅行時間とする。データセットの 2016 年 6 月から 9 ヶ月間を学習データ、残りの 3 ヶ月間を評価データとする。入力には予測対象リンクを含めた複数のリンク旅行時間とする。入力に含める複数リンクのパターンとして、予測対象リンクとその隣接リンクの場合、さらにその複数リンクに隣接しているリンクの場合、といったように全リンク含まれるまで段階的に増やしていく。各パラメータの値は、入力に含めるリンク数を 1 から 33、過去時刻数を 1 から 6、隠れ層のユニットを [10, 20, ..., 100]、隠れ層数 1 から 3 の範囲とする。

4.3 評価指標

評価指標として平方根平均二乗誤差 (RMSE) を用いる。RMSE は以下の式 1 で表され、

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (|f_i - \hat{f}_i|)^2} \quad (1)$$

f_i は教師データ (実測値)、 \hat{f}_i は出力データ (予測値) である。

4.4 実験結果及び考察

比較的リンク旅行時間が大きい Link31 を予測対象リンクとした。上で述べた全パラメータに対して実験を行なった結果、最も RMSE が低かった組み合わせは表 1 のようになり、RMSE は学習データに対して 54.3229、評価データに対して 58.4035 となった。この表 1 のパラメータ構成で学習されたモデルを用いてリンク旅行時間を予測した結果を実測値と比較し

表 1: 最適なパラメータ

パラメータ	値
リンク数	33
過去時刻数	6
入力次元数	198
隠れ層のユニット	[80, 50, 40]
隠れ層数	3




図 3: 実測値と予測値の比較 (Link31) 期間: 2017 年 3 月 1 日~2017 年 3 月 4 日

たものが図 3 である。横軸が時刻、縦軸がリンク旅行時間であり、青線が実測値、緑線が予測値を表している。このプロットの期間は 2017 年 3 月 1 日から 3 月 4 日までである。この図 3 から、大まかな周期は捉えられていることがわかる。

また、出力が Link31 のリンク旅行時間である DNN に対して、入力に含めるリンク数及び過去時刻数を変化させることにより、RMSE にどのような影響を与えるかを調べた。図 4 は、横軸が入力に含めるリンク数の変化で、縦軸が RMSE を表している。入力に含める過去時刻数毎に、リンク数の変化による RMSE の値がプロットされている。この図 4 より、リンク数を増やすことによる RMSE の変化がほとんど見られないことがわかる。図 5 は、横軸が入力に含める過去時刻数の変化で、縦軸が RMSE を表している。入力に含めるリンク数毎に、過去時刻数の変化による RMSE の値がプロットされている。この図 5 から、どのリンク数においても過去時刻数を増やすことで、RMSE の値が減る傾向にあることが分かる。よって、DNN の入力に含める情報として、リンク数を増やすことよりも過去時刻数を増やすことの方が予測精度に大きく影響を与えることが読み取れる。

深層学習による予測手法の妥当性を示すために、重回帰分析及び SVR との比較を行なった結果が表 2 である。また、予測対象リンクとして、リンク旅行時間が比較的大きい Link5 及び Link30 の場合も含めて比較を行なった。各手法を比較した結果、どのリンクにおいても DNN を用いた予測の RMSE が一番小さい値となったが、大差ない結果となっている。本研究での予測手法の妥当性は示されたが、その他手法と比べて大きな精度の向上はみられなかった。これは、本研究で扱ったプローブ情報の補完割合が多いことが関係しており、データセットの補完割合が多いことでデータの多様性がなくなり、非線形関数の近似能力に優れた深層学習の本来の能力が十分に発揮されなかったからであると考えられる。

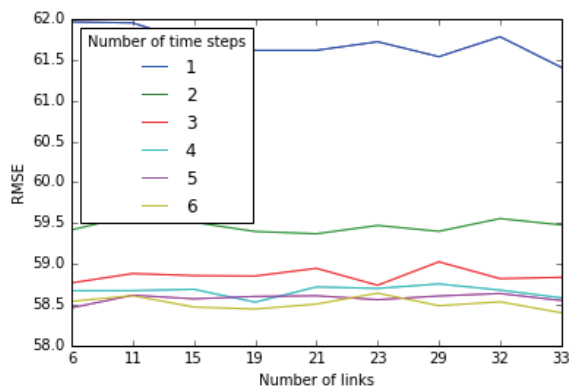


図 4: 過去時刻数毎の、リンク数を変化させた時の RMSE の変化




図 5: リンク数毎の、過去時刻数を変化させた時の RMSE の変化

5. まとめと今後の展望

本研究では、プローブデータを用いた深層学習によってリンク旅行時間を予測し、その検証を行った。対象リンクの時刻 $t+4$ のリンク旅行時間を予測するために、予測先リンクとその周辺リンクの時刻 t 以前のリンク旅行時間を用いて予測した。リンク旅行時間の予測をするにあたって、入力に用いる周辺リンクや考慮すべき時刻の範囲を検証した。その結果、入力として用いる周辺リンクの範囲を広げるよりも、過去の時刻を考慮する範囲を広げる方が精度向上に寄与することが示された。

深層学習による予測結果の妥当性を確認するため、重回帰分析および SVR による予測結果と比較を行った。その結果、深層学習による予測結果の妥当性は示され、僅かに深層学習の方が予測精度が優れていることが示されたが、大差無い結果となった。これは、扱ったデータセットの補完割合が高いことでデータの多様性がなくなったからだと考えられる。

また、本研究では 20 分後のリンク旅行時間の予測を行なったが、現在、5 分後、10 分後、15 分後と予測期間を変えることで結果が変わる可能性も考えられるので、予測期間を変えた実験を行うことも必要である。さらに、入力に含める過去時刻数を増やすことで予測精度に影響を与えることが示されたので、過去時刻数をさらに増やした場合の実験も行う必要がある。

表 2: 各手法による予測結果の比較

	予測先リンク	DNN	重回帰分析	SVR
RMSE	Link5	37.64	38.10	37.80
	Link30	65.42	65.96	66.12
	Link31	58.40	59.60	58.71

謝辞

本研究で使用したデータセットは、住友電気工業株式会社様よりご提供いただきました。心より感謝いたします。

参考文献

- [1] Yoshua Bengio, et al. Learning deep architectures for ai. *Foundations and trends® in Machine Learning*, Vol. 2, No. 1, pp. 1–127, 2009.
- [2] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [3] Ronan Collobert and Jason Weston. A unified architecture for natural language processing: Deep neural networks with multitask learning. In *Proceedings of the 25th international conference on Machine learning*, pp. 160–167. ACM, 2008.
- [4] Geoffrey E Hinton and Ruslan R Salakhutdinov. Reducing the dimensionality of data with neural networks. *science*, Vol. 313, No. 5786, pp. 504–507, 2006.
- [5] Brody Huval, Adam Coates, and Andrew Ng. Deep learning for class-generic object detection. *arXiv preprint arXiv:1312.6885*, 2013.
- [6] Yisheng Lv, Yanjie Duan, Wenwen Kang, Zhengxi Li, and Fei-Yue Wang. Traffic flow prediction with big data: a deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 2, pp. 865–873, 2015.
- [7] Fangfang Zheng and Henk Van Zuylen. Urban link travel time estimation based on sparse probe vehicle data. *Transportation Research Part C: Emerging Technologies*, Vol. 31, pp. 145–157, 2013.