

道路リンクの接続関係を反映した ニューラルネットによる道路交通量予測の検討

吉田 幸司¹・井上 亮²

¹学生会員 東北大学博士課程前期 大学院情報科学研究科
(〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)
E-mail: koji.yoshida@plan.civil.tohoku.ac.jp

²正会員 東北大学准教授 大学院情報科学研究科
(〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)
E-mail:rinoue@tohoku.ac.jp

即時的な観測データを用いた短期間の道路交通量を予測する手法として、深層学習を使用した研究が行われている。道路の接続関係は渋滞などの交通現象が生起する原因となることから、交通量予測の精度に大きな影響を持つと考えられる。しかし、既存研究では、モデルのニューラルネットの構造が、道路の接続関係とどのような関係を持つのか言及していない。本研究では、道路の接続関係を反映したニューラルネットを作成し、市街地一般道の観測データを用いて道路交通量予測を行う。各階層のノード間を全て結合したニューラルネットを用いた予測結果と比較し、その予測性能を検証する。分析の結果、上流や下流の道路ネットワークの情報を集約するニューラルネットを用いることで、予測精度を保ちながら、パラメータ数を削減できることが明らかになった。

Key Words : Deep Learning, Neural Network, Traffic Volume Prediction, Urban Street Network

1. はじめに

交通集中による渋滞は、旅行時間の増加や沿道の環境悪化などを生み出す深刻な社会問題の一つである。この問題の解決に向けて、交通状態を把握し、ドライバーへの情報提供や信号制御などの交通管制に利用することを目的として、路側計器やプローブ車両など様々な技術を利用した交通観測が以前から行われてきた。近年のICTの発展・普及に伴い、即時的な観測データを利用した分析、特に短期間の道路交通量予測が注目を集めている。

交通量予測アプローチの一つとして、多層化したニューラルネット(Neural Network: NN)を用いた深層学習と呼ばれる機械学習手法がある。既存研究は、深層学習を用いた手法がサポートベクトルマシンやランダムウォークを用いた学習手法よりも高度の予測結果を得られることを示している。Lv et al.¹⁾は、NNの層数や各層のノード数などのモデル構造を経験的に決定し、各階層のノード間をすべてリンクで結合したNNを用いて分析している。以後、このようなNNを全結合NNと呼称する。しかし、Lv et al.は、交通現象の生起パターンを形成する道路リンクの位置や接続関係、道路交通のODパターンといった

特徴が学習結果に反映されているかは議論していない。

一般に、深層学習で用いるNNの構造は経験的に決定される。しかし、深層学習の適用が進んでいる画像認識の分野では、パラメータの特徴や構造の意味解釈を行い、学習対象のデータ構造を捉えたNNの構造や重みフィルターを用いて、パラメータ数を削減することが試みられている²⁾。交通状態を対象とした分析においては、Polson and Sokolov³⁾が深層学習と l_1 正則化を用いた線形モデリングを行う層を組み合わせ、交通事故やイベントなどによる非日常的な交通現象に対応した速度予測モデルを提案している。しかし、学習されたNNのパラメータの意味解釈は行っていない。予測結果やパラメータの意味解釈を基に、交通現象の生起パターンを形成する特徴を考慮したNNの構造を検討することは、学習の高速化や予測性能の向上に寄与すると考える。

以上の背景に基づき、本研究では、交通現象の生起パターンを形成する特徴の1つである、道路リンクの接続関係に注目する。接続関係を反映したNNを用いて、全結合NNよりも少ないパラメータ数で交通量予測を行い、全結合NNと予測精度を比較することで、その予測性能を検証する。本検討は、複雑なネットワーク構造を有す

る，都市内一般街路で観測されたデータに基づく交通量予測を行う場合に，高い有用性を有すると期待される。

第2章では，深層学習について概説した後，深層学習による交通量予測に関する既存研究について述べる．第3章では，本研究で提案する，接続関係を反映したNNについて述べる．第4章では，実際の車両感知器のデータを用いて，全結合NNを用いた予測モデル予測性能の比較を行い，提案NNを用いた予測モデルの予測性能を検証する．最後に第5章で本研究の成果と，今後の課題を述べる。

2. 深層学習による交通量予測に関する既存研究

(1) 深層学習

深層学習とは，NNを用いた機械学習手法の総称である．観測データに内在する局所的な特徴とそれらが集まり形成される大域的特徴を特徴量（内部表現）として学習によって推定する．深層学習は，予測・補間について高い性能を有することが，様々なデータへの適用を通して確認されている。

NNは人間の脳神経系におけるニューロンを模擬したパーセプトロンを組み合わせた並列・分散的な情報処理の数理モデルである．パーセプトロンは図-1(a)のようにノードとリンクで表され，その伝播はノード*i*の値を x_i ，層間の各リンクに設定された重みを w_i ，活性化関数を $a(\cdot)$ で表すと，式(1)によって表現できる。

$$y = a\left(\sum_{i=1}^n w_i x_i + b\right) = a(\mathbf{w}^T \mathbf{x} + b) \quad (1)$$

伝播先の各ノードには活性化関数によって変換された値が入力される．活性化関数には，シグモイド関数やRelu関数といった非線形変換を行う関数が設定される。

深層学習では複数の層を持つNNが用いられる．図-1(c)に表した隠れ層を二層持つNNで起こる伝播は，式(1)を入れ子のように組み合わせ，式(2)のように表せる。

$$y = a_3(\mathbf{W}^3 a_2(\mathbf{W}^2 a_1(\mathbf{W}^1 \mathbf{x} + \mathbf{b}^1) + \mathbf{b}^2) + \mathbf{b}^3) \quad (2)$$

NNのパラメータは，NNから出力される値と観測値の誤差を使って，重みを更新することで学習される．重みの更新には確率的勾配降下法といった層ごとに逐次的な更新を行う最適化手法が用いられる．この際，誤差は累積二乗誤差や交差エントロピーなど，分析する対象により経験的に設定される損失評価関数により算出される。

(2) 深層学習による交通量予測に関する既存研究

道路交通量観測データを用いた分析に，深層学習が多く用いられている．例えば，Yongxue et al.⁹⁾は交通量予測




図-1 パーセプトロンとNN

に，時系列データの扱いに優れているとされるLong short-term memory法を適用している．全結合NNのノードの代わりに，前時刻の情報を記録と伝播を行うメモリーユニットを置くことで，情報の伝播のみを行うノードを用いたNNよりも精度よく予測できることを示している．また，Duan et al.⁹⁾は交通量観測データの補間に自己符号化器を用い，予測対象道路リンクの下流の道路リンクの情報を入力情報に加えることで，予測結果の精度が上昇することを示している。

これらの研究では，予測結果の精度の比較や意味解釈から，前時刻の情報や道路リンクの接続関係といった交通現象の生起パターンを形成する特徴が予測精度に与える影響の把握を試みている．一方で，学習に用いたNNの構造が，交通現象の生起パターンを形成する特徴とどのような関係を持つかは言及していない．

3. 道路リンクの接続関係を反映したNNの作成

既存研究では，道路交通量予測に全結合NNを用いている．しかし，交通現象の生起パターンをつくる特徴を考えた場合，時空間的に離れた道路リンクの情報を含めて全てのノードをつなぎ合わせた全結合NNでは，精度に大きな影響を与えないパラメータを多く含んでいることが考えられる．交通現象の生起パターンを形成する特徴を反映したNN構造を用いてパラメータ数を削減することは，学習の高速化や予測精度の向上に寄与する可能性を持つ．本研究では，その特徴の1つである，道路リンクの接続関係に注目して分析を行う。

(1) 基本的な考え方

ある道路リンクの交通流は，その上下流の接続道路リンクの状態に，大きく影響を受けると考えられる．一方で，直接接続していない，また，遠く離れた場所にある道路リンクの交通量との相関は小さいと考えられる．以上の仮定に基づき，道路リンクの接続関係に従って特定の道路リンクの情報のみを集約する性質を持つNNを作成し，パラメータ数の削減を図る。

(2) 道路リンクの接続関係を反映したNN

本研究では、道路リンクの接続関係を反映するNNとして、「入力層と隠れ層一層目のネットワーク構造が、接続関係のある道路リンクの交通量が入力されるノードの情報を集約する構造となるNN」を提案する。本研究では、ある時点の予測対象道路リンクと隣接道路リンクの交通量を入力情報とし、一時刻後の予測対象道路リンクの交通量を出力情報とする予測モデルに適用することを想定したNNを考える。


入力層と隠れ層一層目のノードのネットワーク構造は、道路リンクの接続関係の多様さから、多くのパターンが考えられる。本研究では、まず、図-2に示された2つの単純な道路ネットワーク構造における道路リンクの接続関係に対応したNNを提案する。

a) 直線を形成する道路ネットワークに対応したNN


道路ネットワークの最も単純な分析として、予測対象道路リンクから2次接続道路リンクまで直線上にある道路ネットワーク（図-2(a)）に注目する。直線上では、上下流の交通量が予測対象道路リンクに強い影響を与える。この上下流を形成する複数の道路リンクの交通量は自由流や渋滞流といった、ある状態に集約して考えることができる。そこで、予測対象道路リンクと2次接続までの隣接道路リンクの交通量を、それぞれ集約するネットワーク構造を持つNN_{straight_road}を作成する（図-3(a)）。この際、予測対象道路リンクのパラメータ w_{target}^1 の値は1に固定する。

b) 交差点を含む道路ネットワークに対応したNN

次に、交差点の情報の集約を考える。上流に交差点を持つ道路リンクへの流入情報は、交差点を形成する道路



(a) 直線を形成する道路ネットワーク



(b) 予測道路リンクの上流に複数、下流に一本の一次接続道路リンクを持つ道路ネットワーク

図-2 NNを提案する道路ネットワーク

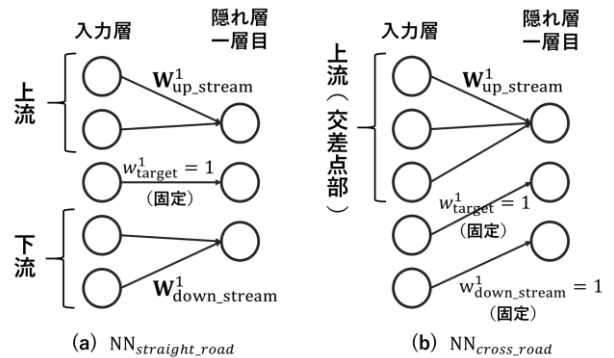


図-3 提案NNの入力層と隠れ層一層目のネットワーク構造

リンクの情報を集約することで表現が可能であると考えられる。そこで、予測対象道路リンクの上流に三本、下流に一本の一次接続道路リンクを持つ道路ネットワーク（図-2(b)）を対象に、交差点の情報を集約するネットワーク構造を持つNN_{cross_road}を図-3(b)のように作成する。この際、予測対象道路リンクのパラメータ w_{target}^1 と下流道路リンクのパラメータ $w_{down_stream}^1$ の値は1に固定する。

4. 提案NNの予測性能の検証

実際の車両感知器観測データを用いて、提案NNと全結合NNを用いた道路交通予測モデルの予測精度の比較を行い、パラメータ数を削減したNNを用いた予測モデルの予測性能を検証する。

(1) 使用データ

沖縄県警より提供された、沖縄本島内般道路のVICSリンクに関する5分間隔の交通量データを用いて分析を行う。

なお、本データには一部欠損があるため、データが欠損している期間の前後の時刻のデータを用いて、欠損箇所を線形補間する。また、リンクごとに平均0、分散1となるように交通量データを基準化した。

本研究では、2011年6月から8月までのデータを用いて学習し、2011年9月のデータを用いて精度検証を行う。

(2) 提案NNの予測性能の検証

予測に用いる提案NNの隠れ層の数を2層とし、同じ層数を持つ全結合NNモデルを用いて、道路交通量の予測精度の比較を行い、予測性能を検証する。

NNのリンクに対応するパラメータの数を固定するために、本検証で用いる予測モデルのNNのノード数は分

析対象道路リンクによらず、表-1に従い一定に設定する。また、全てのNNにおいて、各層の活性化関数を表-2のように設定し、損失評価関数として、以下の式に示す累積二乗誤差 (Mean Squared Error : MSE) を用いる。ここで、 f_i は時刻*i*における観測値、 \hat{f}_i は時刻*i*における予測値を示す。

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - \hat{f}_i)^2 \quad (3)$$

a) 分析1：直線を形成する道路ネットワークにおける $NN_{straight_road}$ モデルの予測性能の検証

日常的な交通状態が異なる4本の道路リンクを対象に検証を行う。各モデルの予測結果を表-3に示す。また、二次メッシュ ID#392767のVICS ID#5と二次メッシュ ID#392745のVICS ID#10の道路リンクの観測値と各モデルの予測値を図-4と図-5に示す。

これらの結果から、直線の道路ネットワークでは上流・下流の情報を集約した $NN_{straight_road}$ を用いて、パラメータ数を半減しても、予測精度を著しく低下させることなく予測を行うことが可能であることが示された。

表-1 各モデルのノード数とリンク総数


モデル	入力層	隠れ層一層目	隠れ層二層目	リンク総数
全結合NN	5	4	2	30
$NN_{straight_road}$	5	3	2	13
NN_{cross_road}	5	3	2	13

表-2 分析に用いるNNの活性化関数

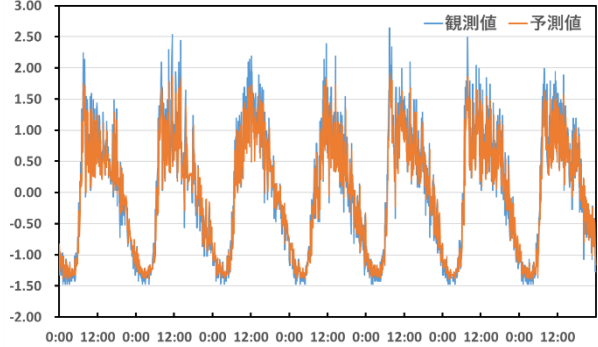
層	活性化関数
隠れ層一層目	シグモイド関数
隠れ層二層目	シグモイド関数
出力層	恒等関数

表-3 分析1における分析結果

予測対象リンクID	リンクの特性	使用モデル	誤差
メッシュ: 392756 VICS:108	自由流	全結合NN	0.170
		$NN_{straight_road}$	0.170
メッシュ: 392767 VICS:5	自由流	全結合NN	0.167
		$NN_{straight_road}$	0.168
メッシュ: 392736 VICS:28	下流で渋滞が発生し、当該リンクまで延伸	全結合NN	0.190
		$NN_{straight_road}$	0.193
メッシュ: 392745 VICS:10	下流で渋滞が発生し、当該リンクまで延伸	全結合NN	0.130
		$NN_{straight_road}$	0.131




(a) 交通量の観測値と全結合NNモデルを用いた予測値




(b) 交通量の観測値と $NN_{straight_road}$ モデルを用いた予測値

図-4 9月1日から7日までの

二次メッシュ ID#392767/VICS ID#5の道路リンクでの交通量の観測値と各モデルを用いた予測値



(a) 交通量の観測値と全結合NNモデルを用いた予測値



(b) 交通量の観測値と $NN_{straight_road}$ モデルを用いた予測値

図-5 9月1日から7日までの

二次メッシュ ID#392745/VICS ID#10の道路リンクでの交通量の観測値と各モデルを用いた予測値

このことから、全結合NNで表現される様な、上下流の入力情報をつなぐネットワークリンクは、交通量予測において予測精度に大きな影響を与えないと言える。

b) 分析2：交差点を含む道路ネットワークにおける

NN_{cross_road}の予測性能の検証

上流の交差点部の交通量が増加し、下流道路リンクまでその影響が波及するような特性を持った道路リンク4本を検証に用いる。各モデルを用いた予測結果を表-4に示す。また、二次メッシュ ID#392736/VICS ID#145の観測値と各モデルの予測値を図-6に示す。

これらの結果から、交差点を形成する道路リンクの情報を集約したNN_{cross_road}を用いることで、パラメータ数を低減しながら、予測精度を著しく低下させることなく予測が可能であることが示された。これは、交差点を形成する道路リンクの情報を集約することで、交差点からの流入を表すような汎用的なノードが形成されたと考えることができる。

5. おわりに

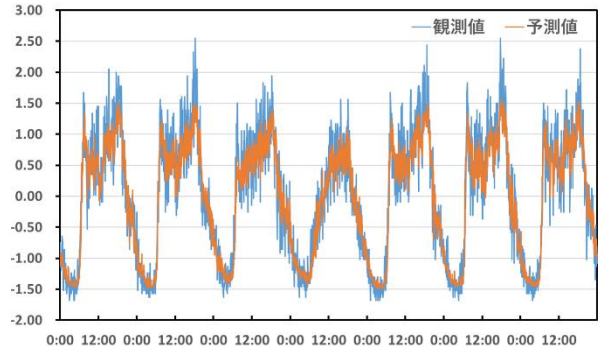
本研究では、道路リンクの接続関係を反映したNNを用いた道路交通量予測を行い、全結合NNからパラメータ数を削減して、全結合NNを用いたモデルと同程度の精度の予測が行えることを示した。具体的には、「直線を形成する道路ネットワーク」と「予測対象道路リンクと一次接続する道路リンクが上流に三本、下流に一本存在する道路ネットワーク」を対象として、入力層と隠れ層一層目のネットワーク構造が、接続関係のある道路リンクの交通量の情報を集約する構造となるNNを作成した。前述の性質を持つNNを用いて交通量予測を行い、パラメータ数を削減しながら、全結合NNを用いた場合と同程度の予測精度を達成できることを示した。

以上の分析から、NNを用いた交通量予測モデルにおいて、道路リンクの接続関係を反映したNNを用いることで、予測モデルに用いるパラメータ数を削減できる可能性が示唆された。

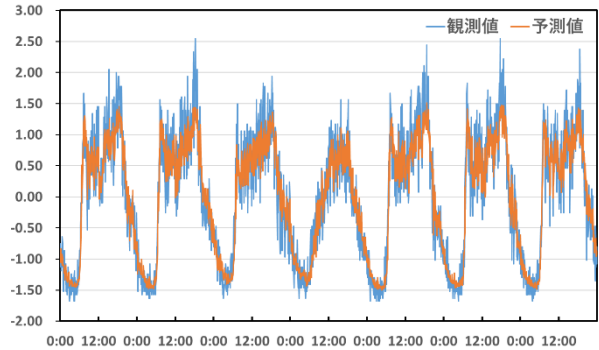
本研究では、直線を形成する道路ネットワークや上流に交差点を持つ道路ネットワークといった、単純な構造の道路ネットワークを対象に分析を行った。市街地における道路ネットワークのような複雑な道路ネットワークにおいても、道路ネットワークの情報を集約するようなNNの構造を用いて、パラメータを削減することができるのか確認することが必要である。また、交通現象の生起パターンを形成する特徴には道路の接続関係といった空間的な特徴だけでなく、前時刻における交通状態の影響といった時間的な特徴が存在する。時間的な特徴を考慮したNNによる、パラメータ数の削減も検討の必要が

表-4 分析2における予測誤差

予測対象リンクID	使用モデル	誤差
メッシュ:392736	全結合NN	0.150
VICS:176	NN _{cross_road}	0.150
メッシュ:392736	全結合NN	0.129
VICS:178	NN _{cross_road}	0.131
メッシュ:392746	全結合NN	0.178
VICS:194	NN _{cross_road}	0.179
メッシュ:392777	全結合NN	0.164
VICS:145	NN _{cross_road}	0.167



(a) 交通量の観測値と全結合NNモデルを用いた予測値



(b) 交通量の観測値とNN_{cross_road}モデルを用いた予測値

図-6 9月1日から7日までの二次メッシュ ID#392736/VICS ID#176の道路リンクでの交通量の観測値と各モデルを用いた予測値

ある。

学習後のNNのパラメータには、観測データの有する交通現象の生起パターンを形成する特徴が表現されている可能性がある。学習したパラメータの意味解釈を行い、深層学習で学習される交通現象の生起パターンを形成する特徴を把握し、この特徴を反映したNNの構造を検討することも今後の課題である。

謝辞：本研究は公益財団法人日本道路交通情報センターとの共同研究の成果である。また、本研究は、JSPS科研費 15H04053の助成を受けたものである。

参考文献

- 1) Lv, Y., Duan, Y., Kang, W., Li, Z. and Wang, F. -Y. : Traffic flow prediction with big data: A deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, 16(2), pp. 865-873, 2015.
- 2) Zeiler, M. D. and Fergus, R. : Visualizing and understanding convolutional networks, *European conference on computer vision*, Springer, Cham. pp. 818-833, 2014.
- 3) Polson, G. N. and Sokolov, O. V. : Deep learning for short-term traffic flow prediction, *Transportation Research Part C*, Vol. 79, pp. 1-17, 2017.
- 4) Yongxue, T. and Li, P. : Predicting short-term traffic flow by long short-term memory recurrent neural network, *IEEE International Conference on Smart City/Social/SustainCom (SmartCity)*, pp. 153-158, 2015.
- 5) Duan, Y., Lv, Y., Li, Y. -L. and Wang, F. -Y. : An efficient realization of deep learning for traffic data imputation, *Transportation Research Part C*, Vol. 72, pp. 168-181, 2016.

(2017.7.31 受付)

SHORT-TERM TRAFFIC VOLUME PREDICTION BY NEURAL NETWORK
BASED ON CONNECTION BETWEEN ROAD LINK

Koji YOSHIDA and Ryo INOUE