

マルチモーダルデータを用いた 交通状況予測に関する考察

中菅 章浩¹・和田 真弥²・小野 智弘³

¹非会員 株式会社KDDI総合研究所（〒356-8502 埼玉県ふじみ野市大原二丁目1-15）
E-mail:ak-nakasuga@kddi-research.jp

²非会員 株式会社KDDI総合研究所（〒356-8502 埼玉県ふじみ野市大原二丁目1-15）
E-mail:sh-wada@kddi-research.jp

³非会員 株式会社KDDI総合研究所（〒356-8502 埼玉県ふじみ野市大原二丁目1-15）
E-mail:ono@kddi-research.jp

近年、道路における交通量や所要時間、交通速度などの交通状況を予測する研究が数多く取り組まれているが、交通状況は大規模イベント有無など、周囲の環境変化に伴い大きく変化する。交通状況をより正確に予測するためには、大規模イベント等による移動需要の変化や、道路間の関係性、曜日特性、交通実績などの多種多様な要素を考慮に入れる必要がある。今日では、このような異なる種別のマルチモーダルデータを組み合わせ、機械学習の手法を適用させることで、周囲の環境変化を考慮に入れた交通状況予測を可能とする研究が多く提案されている。本研究では、マルチモーダルデータを用いた交通状況予測に取り組む海外における研究事例を紹介し、マルチモーダルデータを用いることの有効性の確認と、現状の課題について考察を行い、今後の展望に関する示唆を報告する。

Key Words : 交通行動調査, 交通行動分析, 交通流, 交通情報, 交通量計測

1. はじめに

都市内における交通インフラの整備や、適切な迂回誘導、道路利用者への情報提供を行うためには、現状の交通状況の把握に加え、交通状況の予測を行うことが必要となる。現在、道路上に設置されているセンサにより観測される実測データや、過去の交通状況実績を踏まえた交通状況予測が多く取り組まれているが、現実世界の交通状況は、大規模イベントの有無や、周囲の天候の変化、交通事故や鉄道事故などのアクシデント等、複雑な相互作用によって大きく変化する。

道路利用者へ有益な交通情報を提供するためには、目まぐるしく変化する交通需要を捉え、交通状況の予測へ反映させることが必要となる。このような交通需要の変化を考慮した上で交通状況の予測を行うためには、交通量を直接観測するセンサデータに加え、人流データ、イベント情報、道路間の接続関係、幅員、方向、制限速度、車線数、道路長等の道路情報、天候情報など、種別の異なるマルチモーダルデータを組み合わせることにより交通状況の予測へ反映する必要がある。

今日では、このようなマルチモーダルデータを組み合わせ利用できる深層学習のフレームワークが多く提案されている。

本研究では、はじめに代表的なマルチモーダルデータの紹介とその性質について述べる。次に、基本的な深層学習の手法と、交通状況予測で利用することのできる代表的な深層学習手法について紹介する。さらに、海外における交通状況予測の事例として、Liaoら¹⁾の提案した交通速度予測手法を取り上げ、そのアイデアの概要について解説する。また、再現実験を通して、マルチモーダルデータを用いることによる予測精度の変化とその有効性を確認し、現状の課題について考察を行う。最後に、マルチモーダルデータを用いた交通状況の予測に関する研究の今後の展望について述べる。

2. マルチモーダルデータ

交通状況を把握するために、道路上には様々なセンサが設置されている。交通流の把握には、トラフィックカ

表-1 代表的なマルチモーダルデータ

データ種別	データ項目	粒度	エリア	網羅性	データソース
交通流	交通量, 速度	区間	センサ設置区間	全数	トラフィックカウンタ, CCTV等
人流	人流量	数百mメッシュ	全国	サンプリング	スマートフォンGPSデータ等
道路ネットワーク	区間ID, 幅員, 方向, 隣接区間ID, 延長, 速度制限, 車線数等	道路セグメント	全国	全数	道路情報
曜日傾向	平日, 休日, 祝日ごとのピーク時間, オフピーク時間情報等	道路セグメント	データ蓄積区間	全数	過去実績
イベント情報	イベント開始・終了日時, イベント発生場所	イベント, 場所	全国	全数	イベント集約DB, アプリ等
天候	気象予報	市区町村	全国	全数	気象庁等
交通機関運行情報	支障発生区間, 復旧予定時刻等	駅間	交通機関による	交通機関による	各種交通機関等

ウンタや、CCTVから得られるデータを用いた分析が従来より取り組まれている。交通状況把握に活用することのできる代表的なデータを表-1にまとめた。

前述の通り、交通流の把握には、道路に設置されているトラフィックカウンタや、CCTVのデータを活用することができる。トラフィックカウンタのデータからはカウント数や速度を取得することが可能であるが、CCTVからは動画も得ることができる。

人流データとしては、許諾の得られた利用者のスマートフォンGPSデータを利用することで、全国の人流を統計的に得ることができる。プライバシー保護が可能な単位であれば、最小粒度を数百m以下のメッシュ単位として分析することや、任意の単位でのOD分析を行うことも可能である。

道路ネットワーク情報としては、道路セグメントの接続情報や、幅員、方向性、延長、速度制限、車線数などのデータを利用することができる。道路そのものの特性も、交通状況の変化を把握、予測しようとする上では重要な要素である。

交通流は、曜日の周期性も持ち合わせていると考えられ、平日、休日、祝日における交通流のピーク時間やオフピーク時間などの情報は交通流予測へ活用することができる。

大型イベントの開催前後は、イベント会場へ向かう人々や帰宅する人々の影響から、周辺の交通へ大きな影響を与える可能性があり、事前にイベント開催に関する情報がわかっているならば交通流予測にも活用可能である。

天候についても、人流変化に大きな影響があると考えられる。晴天や雨天などの予報情報は、交通状況の予測

に大きく寄与すると考えられる。

道路の交通流は、鉄道やその他の交通機関の運行状況にも大きく左右される。鉄道の運行が休止になったり、再開されるという情報がわかれば、道路の交通状況の予測へ反映することが可能となる。

以上に述べたように、交通状況の予測に利用することのできるデータの種別は多岐にわたっている。しかし、このように種別が大きく異なるマルチモーダルデータはそのままでは組み合わせることが難しい。現在では、このようなデータから特徴を抽出し、得られた特徴を深層学習の手法を用いて組み合わせることで、マルチモーダルデータを利用した予測タスクを実現する研究が多く取り組まれている。

3. 代表的な深層学習手法

(1) CNN (Convolutional Neural Network)

CNN (Convolutional Neural Network)²⁾ は、畳み込みニューラルネットワークと呼ばれ、画像認識などのタスクによく利用されている深層学習の手法である(図-1)。CNNでは、画像からフィルタを使って特徴を抽出する畳み込み層と、得られた特徴マップを圧縮するプーリング層、最終的な確率を得る全結合層から構成される。画像のピクセル操作から特徴を得る事ができるCNNは、静止画だけでなく動画に対しても応用されることが多い。




図-1 CNNのイメージ図

a) GCN (Graph Convolutional Neural Network)

GCN (Graph Convolutional Neural Network)³⁾は、CNNの考え方をベースとし、深層学習の手法を用いてグラフ構造を畳み込む手法である(図-2)。グラフは、対象を表すノードと、ノード同士を結び関係性を表すエッジからなる。GCNを利用することで、対象ノード周辺やグラフ全体の特徴量を集約し、分類、ランク付け、関係性予測などのタスクを実行することができる。




図-2 GCNのイメージ図

(2) RNN (Recurrent Neural Network)

RNN (Recurrent Neural Network) は、再帰型ニューラルネットワークと呼ばれ、時系列関連のタスクによく利用される深層学習の手法である(図-3)。RNNは、入力層、隠れ層、出力層からなり、前の隠れ層の値を次の隠れ層へ入力することで、過去からの連続性を持ったデータを扱うことに対応している。しかし、長い時系列データでは、過去の情報が消失してしまい、うまく伝達できなくなる課題が存在する。

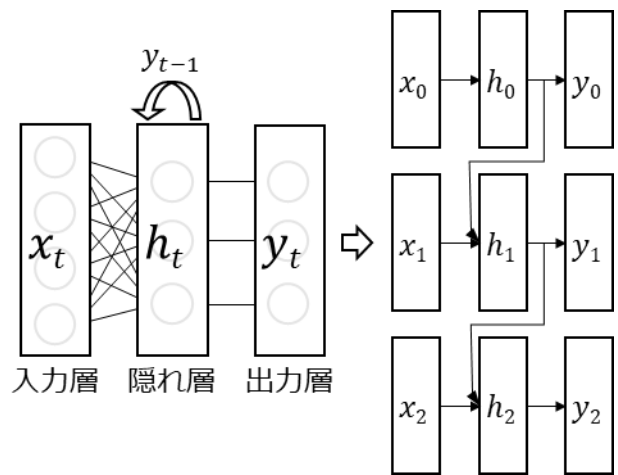


図-3 RNNのイメージ図

a) LSTM (Long Short-Term Memory)

LSTM (Long Short-Term Memory)⁴⁾は、RNNの課題であった、過去の情報が消失する課題を解決できるように考案されたモデルである(図-4)。LSTMでは、RNNの隠れ層部分が、LSTM BLOCKに置き換えられた。LSTM BLOCKでは、どの程度、以前の記憶を忘れるかといった忘却ゲート、どの程度、今回の入力値と前回の出力を組み込むかといった入力ゲート、どの程度、今回の処理結果を出力値とするかといった出力ゲートの3つのゲートにおいてパラメータ調整が行われる。この柔軟性により、以前からの記憶を維持しつつ時系列の処理を行うことが可能となる。

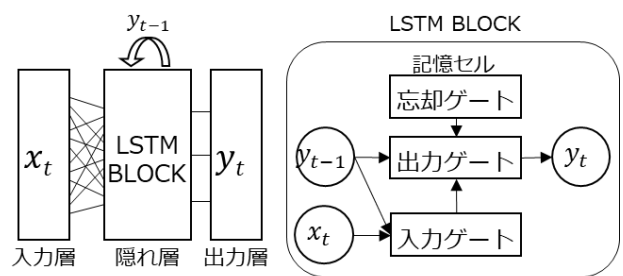


図-4 LSTMのイメージ図

b) Seq2Seq (Sequence to Sequence)

Seq2Seq (Sequence to Sequence)⁵⁾は、RNNを利用して入力時系列を特徴ベクトルへエンコードするエンコーダ部と、特徴ベクトルと出力時系列へデコードするデコーダ部からなるニューラルネットワークモデルである(図-5)。入力時系列とは異なる時系列を出力することができ、機

械翻訳などの分野で利用される事が多い。

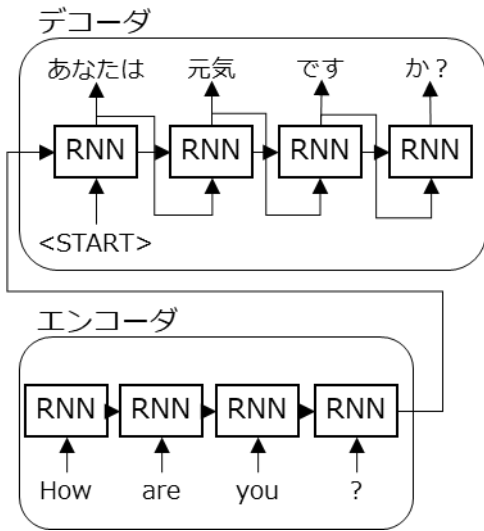


図-5 Seq2Seqのイメージ図

4. 研究事例

海外における事例として、Liaoらの提案した交通速度予測手法について紹介を行う。

(1) 概要

Liaoららは、交通速度の予測を行うため、種別の異なるデータを利用することを考え、下記のデータを統合的に速度予測に組み込む機械学習フレームワークを提案した。

- ・ 速度実績
- ・ 道路構造の地理的構造データ
- ・ 平日、休日、祝日ごとのピーク時間帯、オフピーク時間帯
- ・ マップアプリにおける検索履歴

特に、スマートフォン等におけるマップアプリが広く普及した現在において、マップアプリでの場所の検索履歴は、未来における検索場所に対する移動の潜在的需要を表す可能性が高いことが注目される。さらに、特定地点に対する検索数が多くなるということは、その地点においてイベントが行われる可能性が高いということが予想される。

彼らの提案するフレームワークの概略を図-6に示す。

Seq2Seqのフレームワークにおいて道路セグメント間の依存関係を組み込むために、道路情報をGCNを利用し特徴化を行い、過去の速度実績とともにLSTMへ入力している点が特徴的である。同時に、区間に対する検索回数履歴をLSTMを通して学習させることで、検索回数が交通速度にどう影響するかを得ることができる。さらに、平日、休日や祝日の情報を加えることでより大きな単位の交通変化を考慮に加えている。

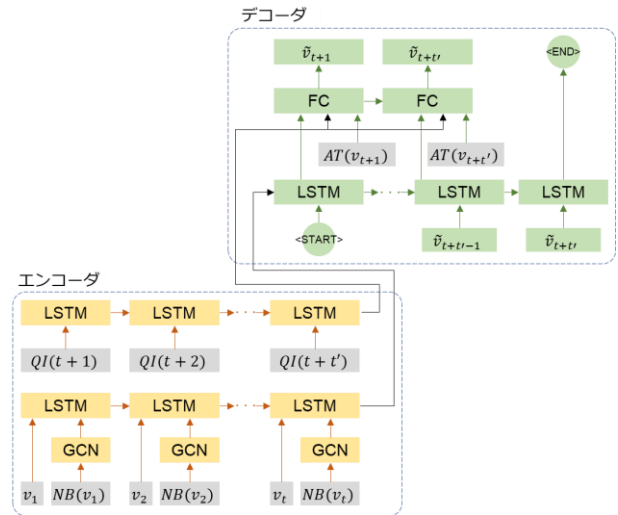


図-6 速度予測手法の概略図

(2) 再現実験

各モダルデータが交通速度予測の精度向上にどの程度寄与しているかを明らかにするため、公開データを利用した再現実験を行った。各モダルを一つずつ加えていった際のMAPE (Mean Absolute Percentage Error) を比較することで、マルチモダルデータを利用することの有効性を確認する。

表-2の通り、従来手法であるRF、SVRと比較し、深層学習の手法を取り入れたSeq2Seqの予測誤差は小さくなった。そこへ平日情報(AT)を加えたSeq2Seq+AT、道路構造情報(NB)と検索履歴情報(QI)を加えたSeq2Seq+AT+NB+QIの順に速度予測誤差が改善することが確認できた。

表-2 再現実験 速度予測誤差率 MAPE (%)

実験パターン	利用データ	15分	30分	45分	60分	75分	90分	105分	120分	全体
RF	交通速度実績	5.96	9.11	10.08	10.47	10.75	10.97	11.17	11.33	9.98
SVR	交通速度実績	5.52	9.29	10.28	10.62	10.82	10.96	11.05	11.14	9.96
Seq2Seq	交通速度実績	4.60	8.21	9.29	9.69	9.92	10.08	10.15	10.32	9.03
Seq2Seq+AT	交通速度実績 平休日情報	4.56	8.12	9.15	9.51	9.70	9.82	9.89	9.97	8.84
Seq2Seq+AT+NB+ QI	交通速度実績 平休日情報 道路ネットワーク情報 マップ検索履歴	4.58	7.99	8.94	9.30	9.54	9.68	9.79	9.89	8.71

5. 考察と今後の展望

再現実験から明らかになったように、単純な速度実績だけでなく、周囲の環境変化を含むマルチモーダルデータを取り入れて交通速度の予測を行うことで、予測精度をより高めることができることがわかった。一方で、今回のデータは事前に完全収集したデータがベースとなっており、実際のサービス提供を考えた際は、よりリアルタイム性のあるデータを用いる必要がある。今後のスマート社会化に向けて、リアルタイムのデータを活用できるよう整備がなされれば、今回利用されなかった天気予報や、公共交通機関の運行情報、さらにはスマートフォンなどGPS情報などのデータを活用することで、トラフィックカウンタなどのセンサが設置されている道路だけでなく、一般道から高速道路における交通流を網羅的に把握し、突発的な環境変化による交通流変化を捉えることができると考えられる。より安全で快適な交通社会の実現のために、横断的なデータ活用が可能となる交通流予測モデルの構築に取り組む予定である。

参考文献

- 1) Binbing Liao, Jingqing Zhang, Chao Wu, Douglas McIlwraith, Tong Chen, Shengwen Yang, Yike Guo, and Fei Wu. 2018. Deep Sequence Learning with Auxiliary Information for Traffic Prediction. In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '18). Association for Computing Machinery, New York, NY, USA, 537-546.
- 2) A. Krizhevsky, I. Sutskever, G. E. Hinton, ImageNet classification with deep convolutional neural networks. Adv. Neural Inf. Process. Syst. 25, 1097-1105 (2012).
- 3) Thomas N Kipf and Max Welling. Semi-supervised classification with graph convolutional networks. International Conference on Learning Representations (ICLR), 2017.
- 4) Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735-1780.
- 5) Ilya Sutskever, Oriol Vinyals, and Quoc V. Le. 2014. Sequence to sequence learning with neural networks. In Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2 (NIPS'14). MIT Press, Cambridge, MA, USA, 3104-3112.

(2021.?? 受付)

A STUDY ON TRAFFIC SITUATION PREDICTION USING MULTIMODAL DATA

Akihiro NAKASUGA, Shinya WADA and Chihiro ONO

In recent years, many studies have been conducted to predict traffic conditions such as traffic volume, travel time, and traffic speed, but traffic conditions change in the surrounding environment, such as large-scale events. In order to predict traffic conditions more accurately, it is necessary to consider a wide variety of factors, such as changes in travel demand due to large-scale events, relationships among roads, characteristics of the day of the week, and traffic records. Nowadays, many studies have been proposed to combine such different types of multimodal data and apply machine learning methods to predict traffic conditions considering changes in the surrounding environment. In this paper, we introduce the overseas studies on traffic forecasting using multimodal data, confirm the effectiveness of using multimodal data, discuss the current issues, and report suggestions for future prospects.