

2021年度阪神高速研究助成（若手研究者助成） 研究概要書

申請者	所属 東京大学 職名 助教	フリガナ 氏名 やすだ しょうへい 安田 昌平
共同研究者	所属 職名	
連絡先	所属 東京大学 職名 助教	フリガナ 氏名 やすだ しょうへい 安田 昌平
	住所 〒113-8656 東京都文京区本郷 7-3-1 電話 03-5841-8090	
研究課題名	ETC2.0 プローブデータを用いた動的な情報提供のための旅行時間予測手法	
研究結果	<p>研究の背景と目的</p> <p>都市高速道路の旅行時間情報を提供することは、利用者と道路管理者の双方にとって有益である。適切な情報提供により、利用者は渋滞を避けた経路や出発時刻の選択が可能となり、道路管理者は道路の効率的な利用を促すことができる。現在、阪神高速道路では車両検知器のデータを用いて推定した旅行時間情報を道路情報板より提供しているが、その情報は特定のランプ間の現時点の旅行時間や混雑状況等に限定されており、また一般道の交通状態は考慮されていない。任意の出発地、目的地、日時の旅行時間を一般道の交通状態も考慮して推定・予測し、動的に情報提供を行うことができれば、より効果的な道路マネジメントの実現に寄与するであろう。近年、国内ではETC2.0等の普及により膨大なプローブデータ（走行軌跡）が収集されており、一般道を含めたネットワークの空間的に連続した観測情報が精度よく取得できるようになった。このような次世代のビッグデータを用いて、任意の日時・地点間の旅行時間予測を効率的に行う手法の開発が求められている。</p> <p>本研究の目的は、阪神高速道路網および周辺的一般道を含むような大規模ネットワーク上で旅行時間予測を高精度かつ高速に行うデータ駆動型の機械学習モデルを実装することである。また過去の交通状態の変動パターンを効率的に学習するための特徴量選択についての比較検証を行うことである。</p> <p>方法論</p> <p>膨大なリンクで構成される大規模ネットワーク上の交通状態の変動パターンを適切に学習するため、時空間依存性を反映した深層学習モデルとして、入力 of 空間的關係を反映可能なニューラルネットワークベースのモデルである Graph</p>	

Convolutional Network (GCN) と、入力の時間的関係を反映可能な Long-Short Term Memory (LSTM) を組み合わせたモデルを構築した。GCN と LSTM の構造例をそれぞれ図 1 と図 2 に示す。

交通状態の変動パターンを効率的に学習するため、入力となる特徴量の選定を行った。具体的には、ネットワークを対象として機械学習による旅行時間予測を行う研究で主に用いられている速度を入力とした場合と、交通状態を非渋滞領域から渋滞領域含め包括的に説明可能な密度を入力とした場合の予測精度の比較を行った。なお、プローブデータを用いてネットワーク内の情報を精度良く観測可能な速度に対して、密度は車両検知器などの固定点観測によってのみ取得可能な指標である。そのため、本研究ではネットワーク内の限られた点で得られた情報を空間的に補間する方法論を、密度が全域で観測可能な交通シミュレーションを用いて検証・選定した。




図 1 GCN の構造例

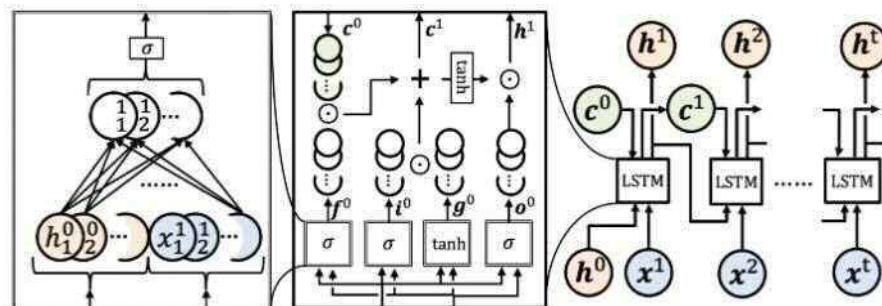


図 2 LSTM の構造例

実データを用いた検証と結果

交通シミュレーションによる検証を行った GCN-LSTM モデルおよび密度補間手法を用いて、実ネットワークを対象とした検証を行った。観測データには ETC2.0 プローブデータと車両検知器データを用いた。対象範囲は阪神高速ネットワークおよび周辺的一般道ネットワークである (図 3)。なおネットワークデータには yasuda et al. 2019 の方法論を用いてプローブデータの観測疎密に応じて定義した空間解像度のネットワークデータを用いた。これにより、一般的に用いられるネッ




図3 実データを用いた検証の対象ネットワーク

トワークデータと比較して大幅な計算コストの削減が可能になり、任意の時間解像度で速度情報などを集計することができている。

実装した GCN-LSTM モデルを用いて約 50 日間の蓄積データを学習し、その後の 1 週間の旅行時間を真値として、直近の過去 150 分間の特徴量を入力として、60 分後の旅行時間予測を行う精度検証を行った。速度と密度を入力とした場合の平均絶対パーセント誤差はそれぞれ約 8.3%と約 7.3%であった。各時刻の真値と、60 分前から本モデルにより予測された値を比較した結果の一例を図 4 に示す。図では値の目安を示すため旅行時間ではなく速度を真値としているが、速度の逆数とリンクの延長を乗じたものが旅行時間であるため精度検証としては適切である。

本研究で構築した GCN-LSTM モデルは事前に蓄積データの学習を行うことで予測自体は 1 秒未満で完了することが確認できており、動的な情報提供システムの実装に寄与する可能性が示された。また、入力として用いる特徴量としてナイーブに予測した密度を入力とした場合の精度が速度を入力とした場合の精度を上回ったことから、特徴量として密度を用いる有用性が示された。

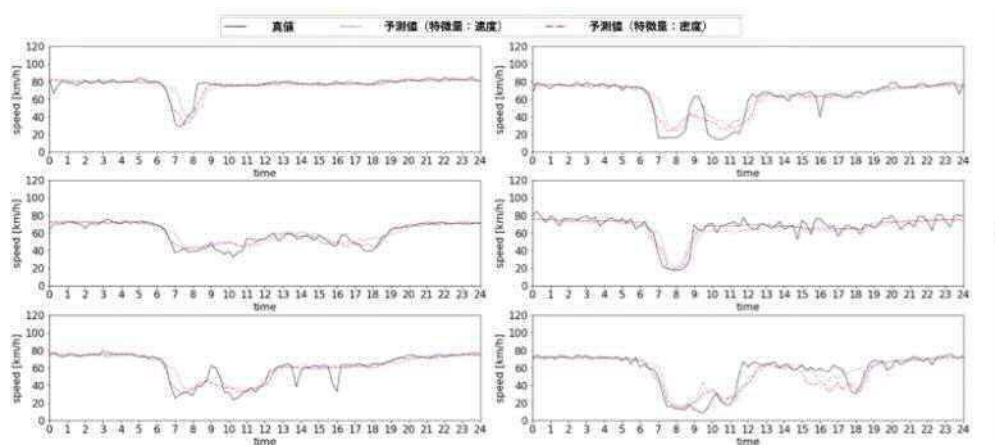


図4 60 分後の旅行時間予測結果と真値の比較