

CNN を用いたディープラーニングによる高速道路渋滞予測モデルの検証

阪神高速道路（株）大阪管理局保全部システム保全課 正会員 ○萩原 武司
 オムロンソーシアルソリューションズ（株） 非会員 幡山 五郎
 オムロンソーシアルソリューションズ（株） 非会員 阿部 敦
 阪神高速技研（株）技術部技術課 非会員 青木 圭

1. 目的

阪神高速道路では交通管制システムの高度化機能の一つとして、渋滞発生・解消の特徴を過去データから捉え、リアルタイムに数分後の渋滞状況を予測するモデルの開発を過年度より進めている。このような予測が精度良く可能となると、これらモデルの出力をキーとして、ボトルネック近傍の情報板や速度回復誘導灯への渋滞軽減施策実施、ボトルネック上流側の入路閉鎖準備指令や実施、解除判断に活用できると考えている。特にこれまではメソ・シミュレーションあるいはミクロシミュレーションモデルを構築し渋滞状況を予測する検討を主に行ってきたが、ネットワーク容量設定等により、予測結果の安定性に課題がある。そこで、直近の 30 秒車両検知器データから取得される「通行台数」と「車両占有時間」から局所的な特徴量をうまく抽出できるように工夫された、画像認識のディープラーニングでよく使われている「コンボリユーション・ニューラルネットワーク」を採用し、渋滞予測への適用可能性を検討した。図-1 のように大きくは前半の畳み込み層（特徴量の抽出）と後半の全結合層に大別できる。




図-1 渋滞予測モデルの構造概念図

2. 検証の概要

渋滞の先頭や発生時間は不規則性があるものの限定的であり、単路線でわかりやすい3号神戸線下り（中之島西～魚崎付近）を対象に、まずは1分後予測を行うこととした。阪神高速道路は追越車線のみ約500mピッチで車両検知器が設置されており、当該区間では53箇所の検知器区間を対象とした。

渋滞予測モデルの推定には、2017年3月1日～3月24日の30秒車両検知器データを使用し、推定したモデルの精度検証には、2017年3月25日～3月31日の30秒車両検知器データを使用した。具体的には、神戸線下りの53箇所の車両検知器（0.5kp～26.4kp）における30秒車両検知器データの台数、占有時間について、直前12時点（6分間）のデータ（合計 $2 \times 53 \times 12 = 1272$ データ）を入力データとし、30秒ごとに1分後の台数、占有時間を予測するモデルである。

表-1 渋滞予測モデルの推定及び渋滞発生予測精度

予測モデル名	渋滞判定予測精度		モデルの構造概略 (CNN層数、最終層のチャンネル数)
	全体	渋滞	
1分後モデル	98.5%	92.1%	3層、12ch

キーワード ディープラーニング、ニューラルネットワーク、渋滞予測、CNN、交通管制システム

連絡先 〒552-0006 大阪市港区石田 3-1-25 阪神高速道路（株）大阪管理局保全部 TEL 06-6576-3881

3. 検証結果

表-1 に非渋滞も含めた全体の判定精度と渋滞のみの判定精度を示すとともに、図-2 は前項で構築した渋滞予測モデルを用いて、2017 年 3 月 25 日（土）の 1 分後予測結果を示しており、真値と比較して大きな差異はないように見える。紙面都合上で割愛しているが、3 月 31 日（金）まで毎日予測し、下図のように取りまとめており、ほぼ同様の傾向で大きな差異もなく予測精度としては実用可能レベルにあると考えられる。




図-2 3号神戸線下りにおける1分後渋滞予測結果（2017年3月25日）

表-2 渋滞発生時（左）解消時（右）の予測割合
（渋滞発生時） （渋滞解消時）

相対時刻	真値	1分後モデル	相対時刻	真値	1分後モデル
0:00:00	0%	1%	0:00:00	100%	100%
0:00:30	0%	1%	0:00:30	100%	100%
0:01:00	0%	1%	0:01:00	100%	100%
0:01:30	0%	0%	0:01:30	100%	100%
0:02:00	0%	0%	0:02:00	100%	100%
0:02:30	0%	1%	0:02:30	100%	100%
0:03:00	0%	1%	0:03:00	100%	100%
0:03:30	0%	1%	0:03:30	100%	100%
0:04:00	0%	2%	0:04:00	100%	100%
0:04:30	0%	2%	0:04:30	100%	100%
0:05:00	0%	1%	0:05:00	100%	100%
0:05:30	0%	2%	0:05:30	100%	100%
0:06:00	0%	2%	0:06:00	100%	95%
0:06:30	0%	3%	0:06:30	100%	98%
0:07:00	0%	2%	0:07:00	100%	98%
0:07:30	0%	3%	0:07:30	100%	98%
0:08:00	0%	6%	0:08:00	100%	98%
0:08:30	0%	8%	0:08:30	100%	93%
0:09:00	0%	18%	0:09:00	100%	91%
0:09:30	0%	39%	0:09:30	100%	84%
0:10:00	100%	70%	0:10:00	0%	77%
0:10:30	100%	95%	0:10:30	0%	37%
0:11:00	100%	98%	0:11:00	0%	21%
0:11:30	100%	100%	0:11:30	0%	12%
0:12:00	100%	100%	0:12:00	0%	2%
0:12:30	100%	100%	0:12:30	0%	0%
0:13:00	100%	98%	0:13:00	0%	2%
0:13:30	100%	98%	0:13:30	0%	5%
0:14:00	100%	98%	0:14:00	0%	5%
0:14:30	100%	96%	0:14:30	0%	7%
0:15:00	86%	92%	0:15:00	12%	12%

さらに表-2 では、左側は渋滞発生時、右側は渋滞解消時における 1 分後の渋滞判定割合を示している。

渋滞発生時においては、実際に渋滞が発生した相対時刻が 0:10:00 であり、その前後の時間帯において 1 分後に渋滞と予測した割合から、予測モデルの速報性について確認できた。

一方、右側の渋滞解消時については、多くが実際に渋滞が解消した後に、渋滞解消を予測する結果となっており、予測の精度としては厳しい結果となった。理由としては、渋滞発生に比較して渋滞解消においては、渋滞要因によりその解消過程に大きな差が生じる影響があるとともに、モデル推定におけるサンプル数そのものの少ない可能性も考えられる。

4. おわりに

今回、1 分後予測を 30 秒車両検知器データから予測する手法を提案し算出したが、渋滞コンター図等をみると予想以上に精度良く予測できることが確認できた。一方、渋滞解消時については、今回の結果から実用化にはまだまだ改善が必要である。

今後は前述の課題に対応しつつ、5 分後予測、10 分後予測、15 分後予測・・・と実用化をにらんだ精度検証を行う予定であるとともに、効果的な教師データ学習期間、入力データの採用期間等について検証していく予定である。さらに、モデル構造や設定等の調整など、運用時におけるメンテナンス事項をいかに軽減できるかについても検証すべきと考えている。

参考文献

・岡谷貴之：深層学習，機械学習プロフェッショナルシリーズ，講談社(2015)。