

CNN を用いたバスの運行予測におけるパラメータ及び活性化関数の選定に関する検討

Study on Selection of Parameters and Activation Functions for Bus Operation Forecasting Using CNN

○盛佑希¹, 三原新大², 野上憲伸², 松村太陽³, 小野隆³*Yuki Mori¹, Arata Mihara², Kenshin Nogami², Taiyo Matsumura³, Takashi Ono³

Buses, which are public transportation systems, are required to be on time, but are affected by traffic congestion. In this paper, the distribution of operation result of multiple buses is obtained, and operation result is predicted by changing the Convolutional Neural Network.

公共交通機関であるバスは定時性が求められるものの交通渋滞の影響を受ける課題がある。そこで本研究は到着予測時刻のリアルタイムな提示による利用者の利便性向上を目的としている^[1]。本稿は、複数便の運行実績の分布を求め、Convolutional Neural Network(以降, CNN)を使用し, CNN のパラメータおよび活性化関数について検討した。

検討区間は街の中心部へ向かう方向の 29 停留所間で, 1 日 72 便である。検討日数は 2022 年 4 月 1 日から 6 月 30 日の平日のうち 48 日分である。学習データは 40 日分, 検証データは 4 日分, 試験データは 4 日分とした。図 1 は 1 便毎の最大遅延時間の度数分布である。最大遅延時間は 1750 [s] の階級に多く分布している。そこで試験データは 1750 [s] の階級から選定した。検証データは 1400 [s], 1750 [s], 2100 [s] の階級からそれぞれ 1, 2, 1 日分選定し, 残りは学習データとした。




Figure 1. Histogram of maximum delay of a bus

CNN の入力先行バス 10 便の各停留所の遅延時間とした。CNN の構成は, 畳み込み層のフィルタサイズが 2×2, 3×3, フィルタ数が 3, 5, 7, 10, プーリング層の有無, プーリング層がある場合のプーリングサ

イズが 2×1, 2×2 の 24 種類を 1 組とし, 全結合層は 1 層又は 2 層で, 活性化関数は 1 層の場合, softmax^[2](手法①), ReLU^[2](手法②), 2 層の場合, 各層ともに ReLU (手法③)とし計 72 種類として検討した。出力は予測対象のバスの各停留所の遅延時間とし, 各手法とも学習回数は 30 回とした。運行予測は, 各手法で学習損失と検証損失が最小となるモデルを用いて行った。

図 2 は, 試験データのうち大きな遅延が発生した朝の通勤時間帯である 6 月 24 日 7 時 44 分発のバスに対して行った予測結果である。各手法は停留所 13 まで運行実績に近い傾向がある。停留所 1~29 の走行時間の予測誤差の絶対値は, 手法①が 9 分 59 秒, 手法②が 4 分 20 秒, 手法③が 1 分 52 秒であり, 誤差は, 手法③が最も少ない結果となった。これらより, フィルタサイズが 2×2, フィルタ数が 10, プーリング層は無し, 全結合層 2 層, 各々の活性化関数に ReLU を用いることで, 各停留所の到着時刻を予測できる見通しが得られた。今後は交通渋滞情報を含めた運行予測について検討する。

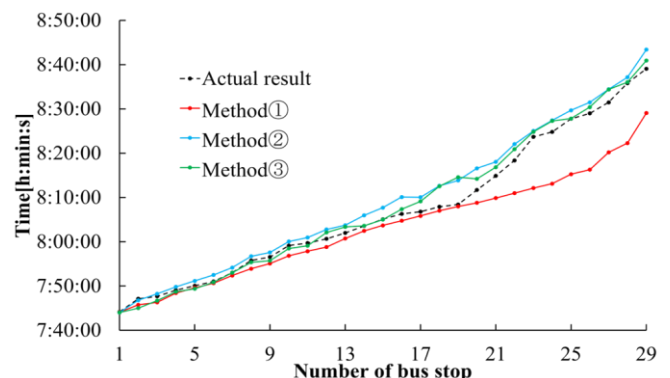


Figure 2. Results of prediction

参考文献

- [1] 山本, 浅野, 松村, 小野, 篠田:「バス運行予測の高度化に向けたリアルタイムなデータの自動取得と運行実績の可視化に関する検討」, 第 64 回日本大学理工学部学術講演会, L-45, pp.661, 2021.
- [2] 三品, 濱田, 五十嵐:「実用的な秘密計算ディープラーニングの実現」, コンピュータセキュリティシンポジウム 2019 論文集, 2019, pp.315, 2019.