

# Attention機構を使った配車車両未確定状態における タクシー到着時間予測

高橋 文彦†

†JapanTaxi 株式会社

## 1 はじめに

到着時間の予測は交通サービスにおいて重要な機能の一つである。タクシーの配車サービスの場合、アプリや電話で依頼された場所（お迎え場所）への到着時間予測と、乗客がタクシーに乗った後の目的地への到着時間予測がある。我々は前者のお迎え場所への到着時間を予測する機能の開発を進めている。

多くのタクシー会社の場合、乗客が配車依頼をすると、依頼を配車システムが受け取り、システムが複数の配車候補の運転手に通知、最初に依頼を受諾した運転手の車両が配車車両に決定、配車車両がお迎え場所に向かう。このため、配車車両の決定はシステムだけで完結せず、実際に配車依頼をするまでの車両が配車されるかはわからない。したがって、お迎え場所への到着時間予測では、複数の配車候補の車両がある状況において到着時間を予測する方法が必要である。

このような課題に対して我々は End-to-End のディープニューラルネットワークモデルにより予測する方法を提案する。機械翻訳や画像分類のタスクでは、予測の際に特定の入力に注目する Attention 機構が有効なことが知られている [1][2]。そこで配車候補の車両情報に Attention 機構を適用したモデルを提案する。実際のタクシー配車データを用いて実験し、提案するモデルと Attention 機構を使わないモデル、経路探索によるモデルを、到着時間の絶対誤差を比較して評価する。

## 2 関連研究

カーナビゲーションなどで使われる商用の車両到着時間予測では、経路探索をベースにし経路距離から到着時間を予測する方法が用いられるが、Wang ら [3] は経路の情報をリカレントニューラルネットワークで再帰処理し、他の特徴量と結合するモデルを使うことで、経路の情報を考慮しつつ到着時間を予測する方法を提案している。また、Asghari ら [4] は到着時間の予測には確率分布で推定する必要があることを主張し、実際の走行データを用いてこの確率分布を推定する手法を提案している。これらの研究は出発地と目的地が明確な状況を前提としているが、本研究では出発地の候補が複数ある状況を扱うためこれらの研究と異なる。

## 3 提案手法

Attention 機構を用いた End-to-End のニューラルネットワークモデルを使って到着時間を予測する。モデル

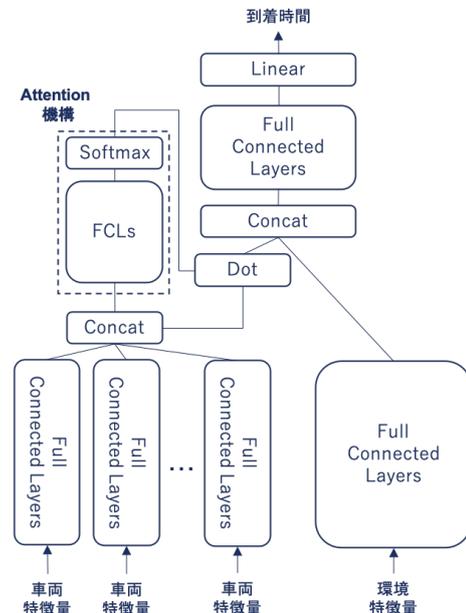


図 1: Attention 機構を用いた到着時間予測モデル

の概要を図 1 に示す。

Attention 機構は自然言語処理や画像処理の分野で使われるネットワーク構造の一つである [1][2]。系列データに適用されることが多いが、本研究のような系列データではない場合にもその構造は適用できる。配車候補の車両ごとの特徴量に Attention 機構を適用し、実際に配車される車両の重みが大きくなることを期待する。

車両特徴量は、車両の緯度経度、お迎え場所の緯度経度、お迎え場所までの直線距離、配車候補の中での直線距離の順位、車両の方向、速度、お迎え場所への方向を用いる。環境特徴量は、曜日、休日かどうか、祝日かどうか、時間、時間帯、日付、月を用いる。

車両特徴量、環境特徴量をそれぞれエンコードし、結合したテンソルを複数の全結合層に通すことで最終的な予測値を得る。loss 関数には絶対誤差を用いる。

## 4 評価と考察

実際のタクシー配車のデータを使って本手法の評価を行う。日本交通\*の9月から12月の東京都を中心とした配車データを用いて、システムが返す到着時間を正解データとして扱う。推定値と正解値の平均絶対誤差 (MAE) を比較して評価する。

\*<http://www.nihon-kotsu.co.jp/sp/>

Method	MAE	Elapsed Time
AttentionNeuralModel	156.11	0.0360
NeuralModel	164.02	0.0385
RouteSearchAverage	166.72	0.0729
RouteSearchOneBest	215.70	0.0731

表 1: 各手法の平均絶対誤差と平均推定時間

比較する手法は、

- AttentionNeuralModel: 提案するモデル.
- NeuralModel: 提案するモデルの Attention 機構部分を使わないモデル.
- RouteSearchAverage: 各車両から目的地までの時間を経路探索によって計算しその平均値を計算.
- RouteSearchOneBest: 直線距離がもっとも近い車両から目的地までの時間を経路探索によって計算.

また実サービスで使う場合その処理時間はシステム選定において重要な指標の一つである. そこでそれぞれの手法の推論時間を計測しその平均時間を比較する.

評価結果を表 1 に示す. 提案手法 (AttentionNeuralModel)

がもっとも MAE が小さい結果となった. また, NeuralModel は AttentionNeuralModel より MAE が大きいことから, Attention 機構が車両未確定状態での到着時間予想に対して有効なことがわかる. RouteSearchOneBest は RouteSearchAverage に比べて MAE が大きい. このことから直線距離がもっとも近い車両だけを考慮するだけでは到着時間の推定に不十分であることがわかる.

推論時間は, 経路探索に基づく手法 (RouteSearchAverage, RouteSearchOneBest) に比べて機械学習に基づく手法 (AttentionNeuralModel, NeuralModel) は半分程度であった. 処理時間はそれを実行するコンピュータのスペックや実装, プログラミング言語に依存するが, 本実験環境の場合, 機械学習に基づく手法の方が経路探索に基づく手法よりも推論時間が短かった.

図 2 と図 3 は, AttentionNeuralModel と RouteSearchAverage の到着時間ごとの精度を折れ線グラフ, 学習データの到着時間のヒストグラムを棒グラフで表したものである. 絶対誤差の割合が 20% 以下のものを正解とみなして精度を計算している. 400 秒以下では RouteSearchAverage は AttentionNeuralModel に比べて精度が高い. これは 400 秒以下のデータが少ないためだと考えられる. また 1000 秒以上の精度はいずれの手法でも精度が低い. 1000 秒以上かかる場合は突発的な道路渋滞などにより予測よりも時間がかかっていると考えられる. このような突発的な要因を特徴量で表現しモデルに組み込むことで精度の改善が期待できる.

## 5 まとめ

配車される車両が未確定の状態において, 配車候補の複数の車両の情報をを用いて到着時間を予測する方法

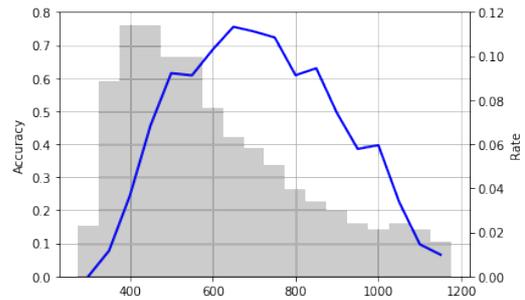


図 2: 到着時間ごとの AttentionNeuralModel の精度 (折れ線グラフ) と学習データの量 (棒グラフ)

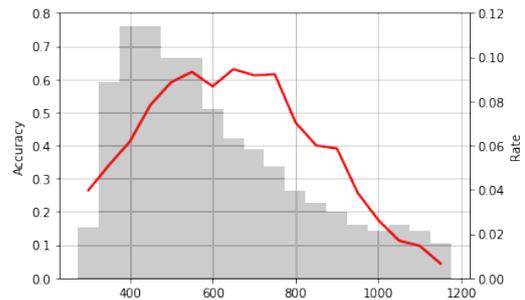


図 3: 到着時間ごとの RouteSearchAverage の精度 (折れ線グラフ) と学習データの量 (棒グラフ)

を提案し, 実験により比較手法よりも平均絶対誤差が小さいことを確認した. 本研究の成果はスマートフォンアプリ JapanTaxi\*で応用されている.

## 参考文献

- [1] Thang Luong, Hieu Pham, and Christopher D. Manning. Effective approaches to attention-based neural machine translation. In *Proc. of EMNLP 2015*, pp. 1412–1421.
- [2] Fei Wang, Mengqing Jiang, Chen Qian, Shuo Yang, Cheng Li, Honggang Zhang, Xiaogang Wang, and Xiaoou Tang. Residual attention network for image classification. *CVPR 2017*, pp. 6450–6458.
- [3] Zheng Wang, Kun Fu, and Jieping Ye. Learning to estimate the travel time. In *Proc. of KDD 2018*, pp. 858–866.
- [4] Mohammad Asghari, Tobias Emrich, Ugur Demiryurek, and Cyrus Shahabi. Probabilistic estimation of link travel times in dynamic road networks. In *Proc. of SIGSPATIAL 2015*, pp. 47:1–47:10.

\*<https://japantaxi.jp>