

畳み込み双線形ポアソン回帰を用いたオンライン交通流予測

大川 真耶[†] 金 秀明^{†,‡} 戸田 浩之[†]

[†] 日本電信電話株式会社 NTT サービスエボリューション研究所 〒239-0847 神奈川県横須賀市光の丘 1-1
[‡] 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所 〒619-0237 京都府相楽郡精華町光台 2-4
 E-mail: †{okawa.maya,kin.hideaki,toda.hiroyuki}@lab.ntt.co.jp

あらまし 交通流予測は、交通需要マネジメント (TDM) において重要な役割を持つ。交通流は、周期変動だけでなく、マネジメント等の外的要因の影響で動的に変化する。予測とマネジメントを繰り返す TDM システムにおいては、マネジメントそのものの影響による交通流の変化を捉えるため、施策実施後の直近のデータのみに基づいてモデルの学習を行う必要がある。本稿では、潜在因子モデルを既存の予測モデルに導入することで短期間のデータのみに基づいて頑健に予測を行う手法を提案した。また、提案モデルに確率的変分ベイズを適用し、パラメータのオンライン学習アルゴリズムを導出した。評価実験により、提案手法は従来法と比較して直近のデータのみを学習に用いた場合により頑健な予測ができることを確認した。

キーワード 交通流予測, GPS, ポアソン回帰, 双線形回帰, 潜在因子モデル

1. 序 論

世界各国の都市において、道路の混雑が大きな社会課題になっている。これに対し、道路の拡張等交通需要の拡大に合わせたハード面の整備に加え、交通需要そのものを調整する取り組みが進められている。後者は道路や駐車場料金の調整、カーシェアリング、時差通勤等幅広い施策を含み、交通需要マネジメント (TDM) の名の下で体系化されている [1]。交通流予測は、TDM の重要な一角をなす。例えば、混雑予測情報の配信は道路利用者の自主的な経路変更を促し、自律的な交通分散につながる。また、適切な施策を選定するためには、施策を実施する近未来の時刻における交通状況を正確に把握する必要がある。本研究では予測とマネジメントを交互に行うシナリオを想定し、TDM への応用を念頭に置いた予測技術の構築に取り組む。

TDM への応用という観点から、以下の三つを予測技術の要件として設定した。(1) 長期予測: 施策の選定・実施に時間がかかる場合には、それらの時間を考慮した比較的長期の予測が必要である。(2) 都市にまたがる複数の道路での予測: エリア全体を最適化するためには、単一の道路だけでなく対象エリアに含まれる複数の道路上の交通流を同時にモデル化する必要がある。(3) 短期間のデータを用いた予測: 交通流は、曜日や時間帯に応じた周期変動だけでなく、マネジメント等の外的要因の影響で動的に変化する。例えば、ある有料道路の料金を値下げした場合、その道路に並行して走る既存の道路の交通流は減ることが予想される。逆に、その道路に接続している別の道路の交通流は増加する。施策実施後の交通流の変動を捉えるためには、施策実施後の直近のデータのみに基づいて予測を行うアプローチが有効である。

複数の道路で交通流を予測する手法としては、一般に以下の二つのアプローチが考えられる。一つ目は、個々の道路ごとにモデルを構築し各道路で独立に学習・予測を行う方法である。この方法は道路ごとに個別のパラメータを仮定するため、多数

のパラメータを必要とする。従って学習データが限られている場合に予測性能が下がるリスクがある。

二つ目は、複数の道路あるいはエリアを包括的にモデル化し同時予測を行う手法である。例えば、人流モデリング分野において、エリアに共通する周期パターンを仮定し複数のエリアをまとめてモデリングすることで複数エリアにおける人口を同時に予測する手法が提案されている [2]。この手法は全てのエリアに対して単一のモデルを当てはめているが、各エリアに紐付いたイベント情報等の外部情報を説明変数として用いることでエリア間の差異を考慮することができる。しかし交通分野においては、外部情報と道路をどう紐付けるか、という点は自明でない。一方、道路間に共通する時間変化パターンと道路間の差異をデータから同時に学習する手法も提案されている [3]。この手法は交通流の履歴のみに基づいて学習を行うもので、外部情報を必要としない。ただし数タイムステップ前の値からの時間発展のみをモデル化しており、周期性を考慮しない。長期の予測においては、短期の時間発展よりも周期成分が支配的になると考えられる。

本稿では、直近の数週間程度のデータのみを用い、複数の道路において数日程度の比較的長期の予測を行う手法を提案する。短期間の限られたデータに対処するため、潜在因子モデルを導入する。潜在因子モデルは複数の道路に共通する潜在プロセスを仮定することでモデルパラメータの削減を実現し、限られたデータに対しても頑健に働くものである。提案モデルは道路に共通する周期パターンを潜在プロセスとしてモデル化し、各道路における交通流を潜在周期パターンの混合で表現する。これにより、道路に共通する周期パターンと道路間の差異を同時に捉えることができる。本研究では、提案モデルに確率的変分ベイズを適用し、パラメータのオンライン学習アルゴリズムを導出した。最新のデータを用いてパラメータを逐次更新することで周期パターンの動的な変化をモデルに反映させることができる。また、実データを用いた評価実験により、提案手法は従来法

と比較して直近のデータのみを学習に用いた場合により頑健な予測ができることを確認した。

2. 関連研究

交通流予測をテーマとする研究は多数存在する [4]。複数の道路で交通流を予測する手法としては、一般に以下の二つのアプローチが考えられる。一つ目は、予測地点それぞれでモデルを構築し、独立に予測を行う方法である。単一の道路における予測手法として、ARIMA [5], [6], カルマンフィルタ [7] 等の時系列モデルやノンパラメトリック回帰 [8], [9], ニューラルネットワーク [10], [11], サポートベクトル回帰 (SVR) [12], [13] を用いた手法が提案されている。しかしこれらの手法は周期性を考慮しない。強い周期性を持つ交通流データにおいては、季節型 ARIMA [14] や季節型 SVR [15] がより良い予測性能を示すことが実験で確かめられている。しかし、道路ごとのモデルを構築する方法は、多数の (道路ごとの独立な) パラメータを必要とする。そのためデータが限られている場合、予測性能の低下を招くリスクがある。

二つ目のアプローチは、全ての道路におけるデータをまとめてモデリングする方法である。時系列モデルの多変量への拡張 [16], [17], [18], [19] や空間情報を入力としたニューラルネットワーク [20], [21] が提案されている。これらの方法は一つ目のアプローチと同様、道路ごとの多数のパラメータを必要とするため、学習データが限られている場合に過学習に陥る可能性がある。限られたデータに対処するため、潜在空間モデリング手法を用いるアプローチが提案されている。例えば、テンソル分解を用いて欠損データの補完を行う手法 [22], [23], [24] や非負値行列分解 (NTF) を用いて交通流の異常検知 [25] を行う手法、交通渋滞の時空間構造を分析する手法 [26] がある。一方、道路間に共通する時間変化パターンと道路間の差異をデータから学習する手法も提案されている [3]。ただしこれらの手法は短期的な時間発展 (数ステップ前の値と現在の値の関係) のみをモデル化しており、周期性を考慮しない。長期の予測においては、短期間の時間発展よりも周期成分が支配的になると考えられる。動的テンソル分解に基づく予測モデルも提案されている [4]。この手法は周期パターンの時間的変動を捉えることができるが、長期の学習データを必要とする。人流モデリング分野においては、複数のエリアに共通する周期パターンを単一の双線形回帰モデルでまとめてモデリングすることで複数エリアにおける人口の変化を同時に予測する手法が提案されている [2]。この手法は全てのエリアに対して単一のモデルを当てはめているが、各エリアに紐付いたイベント情報等の外部情報を説明変数として用いることでエリア間の差異を考慮することができる。しかし交通分野においては、外部情報と道路をどう紐付けるか、という点は自明でない。

本研究は双線形回帰モデルを以下の二点で拡張する。まず、ベイズモデルの枠組みで双線形回帰モデルを定式化する。これにより、確率的変分ベイズ [27] 等のベイズ推論アルゴリズムの適用が可能になる。さらに、潜在因子モデリング手法を双線形回帰モデルの枠組みに導入する。これにより、短期の限られた

Tokyo Routes

- A ME C2 (Central Circular Route)
- B ME 5 (Ikebukuro Line)
- C ME 1 (Ueno Line)
- D ME 6 (Mukojima Line)
- E ME Y (Yaesu Route)
- F ME 4 (Shinjuku Line)
- G ME C1 (Inner Circular Route)
- H ME 3 (Shibuya Line)
- I ME 2 (Meguro Line)
- J ME 1 (Haneda Line)
- K ME B (Bay Shore Route)

Kanagawa Routes

- L ME K6 (Kawasaki Line)
- M ME K1 (Yokohane Line)
- N ME K3 (Kariba Line)



図 1 本実験で用いた首都高速道路上の 14 のセグメント (“セグメント”と呼ぶ)。色は各セグメントに対応する。簡単のため、各セグメントに文字を振り当てた。赤のポイントは東京駅、青のポイントは横浜駅に対応している。

データに対しても頑健な予測ができるようになる。

3. 基礎分析

モデル構築にあたって交通流の基本的な性質を確かめるため、実データを用いた基礎分析を行った。本節ではまず道路セグメントの定義について説明し、その後主な分析結果について述べる。

3.1 道路セグメント

本稿では、首都高速道路の各ルートにおける交通流の変化をモデリングする。首都高速道路 (ME) は 24 のルート (以後 “セグメント” と呼ぶ) からなる道路ネットワークである。本研究では ME の 14 のセグメントに焦点をあて、各セグメントにおける単位時間当たりの交通量の変化をモデル化する。本研究で用いたセグメントを図 1 に示す。簡単のため、各道路にアルファベットを割り振った。図 1 の赤のポイントは東京駅、青のポイントは横浜駅に対応している。

3.2 基礎分析結果

交通流の基本的な性質を調べるため、首都圏エリアで取得した自動車の GPS ログデータを用いて実証分析を行った。主な観測結果 (1. 周期性, 2. 時差相関) について述べる。

3.2.1 時間 × 曜日の周期性

交通流は 24 時間ごと、1 週間ごとの二種類の周期性を持つ。図 2, 図 3 に例を示す。図 2 は三つの道路における一時間おきの交通量を 10 日間分プロットしたものである。図からわかるように、交通流データは 24 時間周期で変動する。図 3 は三つの道路における 2 週間分の交通流を 1 日ごとに集計したものである。左の線は第 1 週 (2015/4/15-22)、右の線は第 2 週 (2015/4/23-30) に対応する。曜日ごとの変動は二つの週でよく似た傾向を示す。月曜から土曜にかけて増加し、日曜に減少する。

二種類の周期性は独立ではなく、7 日間の周期の中にさらに 24 時間の周期が入れ子状で存在する。一例として、図 4 にセグメント B における 1 日の交通流の変化を示す。2015/4/15-5/15

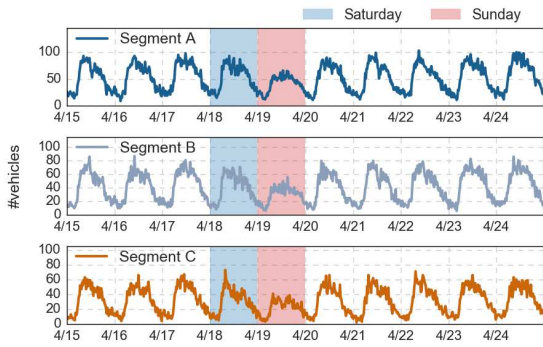


図 2 1 時間ごとに集計した A, B, C 3 つのセグメントにおける 2015/4/15-25 までの交通流の推移交通流データは 24 時間周期で変動する。

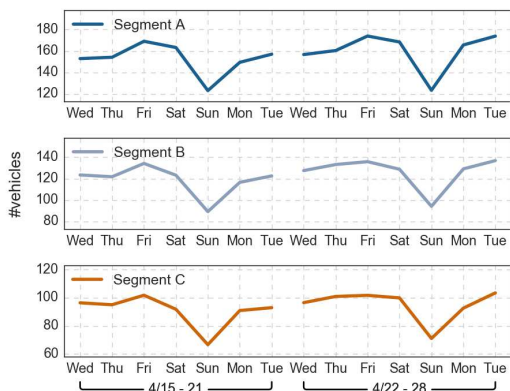


図 3 三つの道路における 2 週間分の交通流を 1 日ごとに集計したもの。左の線は第 1 週 (2015/4/15-22), 右の線は第 2 週目 (2015/4/23-30) に対応する。曜日ごとの変動は二つの週でよく似た傾向を示す。月曜から土曜にかけて増加し、日曜に減少する。





図 4 セグメント B における 1 日の交通流の変化。2015/4/15-5/15 の一ヶ月間にわたって時間帯ごとに平均を取り、平日と休日に分けてプロットした。直線は平日、点線は休日の交通流の変化を表す。平日には朝 7 時から 10 時にかけて通勤ラッシュに対応するピークが見られる。一方、休日には交通量はゆるやかに遷移する。


の一ヶ月間にわたって時間帯ごとに平均を取り、平日と休日に分けてプロットした。直線は平日、点線は休日の交通流の変化を表す。平日には朝 7 時から 10 時にかけて通勤ラッシュに対応するピークが見られる。一方、休日には交通量はゆるやかに遷移する。

3.2.2 道路間の時差相関

図 2 から明らかなように、複数のセグメントにおける交通流は似た周期性を持つ。複数のセグメントにおける交通流同士の関係を定量的に評価するために、各道路における一時間おきの



(a) セグメント K と I の間の時差相関



(b) セグメント L と G の間の時差相関

図 5 二つの道路のペアにおける一時間ごとの交通量の時差分散。右上の r はそれぞれのピアソン相関スコアを表す (p-value は全て 0.001 以下)。

交通流の変化について総当たりで時差相関を調べた。相関分析の結果、全ての道路ペアにおいて強い相関が見られた。また、いくつかの道路ペアにおいて時差相関が見られた。図 5 は二つのペアの時差つき分散図である。図 5a はセグメント K とセグメント I の間の時差相関、図 5b はセグメント G とセグメント L の間の時差相関を示す。セグメント G と I は東京の都心部に位置している。一方 L と K は神奈川県にある。それぞれの図は異なる 3 つのタイムシフトについての相関を表し、左が時差なし、中央が 20 分の時差、右が 40 分の時差に対応する。右上の r はそれぞれのピアソン相関スコアを表す。p-value は全て 0.001 以下であった。全てのペアについて強い相関が見られるが、40 分間のラグを取ったものが最も高い相関係数を示している。この結果は、複数道路間の時差相関を示唆している。他の道路ペアについても似た結果が得られたが、特に東京都心部と神奈川県南部等、異なる都市における道路間でこの傾向は顕著であった。

4. 定式化

交通流のある時間帯にある道路セグメントを通過した車の台数として定義する。あらかじめ定めた固定の時間幅 (例えば 20 分間) で 1 日 24 時間を複数の時間帯に分割する。 $v = 0, 1, \dots, V$ を時間帯のインデックスとする。ここで V は時間帯の数である。時間幅が 20 分なら、 $V = 72$ となる。道路 r における i 番目のデータ (交通量) $y_{i,r}$ は時間帯 $v_{i,r}$ 、曜日 $u_{i,r}$ を用いてタプル形式で表すことができる: $(y_{i,r}, v_{i,r}, u_{i,r})$ 。本稿では、祝日を第八の曜日とする。時間帯 $v_{i,r}$ と曜日 $u_{i,r}$ を 1-of- K 表現に変換すると、交通流は新たな形式のタプル $(y_{i,r}, \mathbf{t}_{i,r}, \mathbf{d}_{i,r})$ で書ける。 $\mathbf{t}_{i,r}$ は $v_i = v$ なら v 番目の要素が 1、それ以外なら 0 の V 次元のベクトルである。同じく、 $\mathbf{d}_{i,r}$ は $u_i = u$ なら u 番目の要素が 1、それ以外なら 0 の U 次元のベクトルである。ここで $U = 7 + 1$ (日曜日、月曜日、..., 土曜日 + 祝日) である。本研究のゴールは過去の交通流の履歴 $\{(y_{i,r}, \mathbf{t}_{i,r}, \mathbf{d}_{i,r}) | i = 1, \dots, n, r = 1, \dots, R\}$

が与えられた下で任意の道路 r における時間帯 $\mathbf{t}_{*,r}$, 曜日 $\mathbf{d}_{*,r}$ の交通量を予測することである。

5. 提案手法

本節では、提案手法の畳み込み双線形ポアソン回帰モデルについて説明する。概観を紹介した後モデルの定式化について詳細を述べ、最後に推論アルゴリズムを示す。

5.1 概観

本稿では、既存の回帰手法に潜在因子モデルを導入することで新たな交通流予測モデル (畳み込み双線形回帰) を構築する。図 6 に提案法の概略図を示す。提案法は周期パターンを潜在プロセスとしてモデル化し、潜在周期パターンを各道路における交通流データから学習する。各道路の交通流は潜在周期パターンの混合で表現される。周期パターンを表す潜在プロセスは双線形ポアソン回帰でモデル化される。これにより、掛け算の周期性を捉えることができる。また、周期パターンを混合する際に畳み込みを用いることで道路間の時差相関を考慮する。

5.2 提案手法

ベースライン手法の双線形ポアソン回帰の定式化にのっとり、まず交通量 $y_{i,r}$ がポアソン分布に従うという仮定を置く。

$$p(y_{i,r}; \lambda_{i,r}) = \frac{e^{-\lambda_{i,r}} \lambda_{i,r}^{y_{i,r}}}{y_{i,r}!}, \quad (1)$$

ここで $\lambda_{i,r}$ はポアソン分布の平均である。ポアソン分布の平均が曜日 $\mathbf{d}_{i,r}$ と時間帯 $\mathbf{t}_{i,r}$ の掛け合わせの周期性を持つと仮定する。

$$\lambda_{i,r} = \mathbf{d}_{i,r}^\top \mathbf{W} \mathbf{t}_{i,r},$$

ここで \mathbf{W} は $U \times V$ の行列である。ベースライン手法に従い、共変量行列 \mathbf{W} を二つの低ランク行列 (B と Θ) に分解する。

$$\lambda_{i,r} = \mathbf{d}_{i,r}^\top B \Theta \mathbf{t}_{i,r}, \quad (2)$$

ここで B は $U \times K$ の行列、 Θ は $K \times V$ の行列である。 \top は行列あるいはベクトルの転地を表す。分解後の行列のランク K は $K \ll \min(U, V)$ になるように設定される。(2) 式はベクトル形式で書き換えることができる。

$$\lambda_{i,r} = \sum_{k=1}^K \mathbf{d}_{i,r} \beta_k^\top \theta_k \mathbf{t}_{i,r}, \quad (3)$$

ここで $\beta_k = [\beta_{k1}, \dots, \beta_{kU}]$ は B の k 番目の列、 $\theta_k = [\theta_{k1}, \dots, \theta_{kV}]$ は Θ の k 番目の行である。 β_k は k 番目の潜在因子の週ごとの周期性、 θ_k は k 番目の潜在因子の日ごとの周期性と解釈することができる。各々のベクトルを週基底、日基底と呼ぶ。

まず、ベースライン手法をベイジアン NMF の枠組みで記述する。[28] の手順に従って、パラメータ β_{uk}, θ_{kv} に事前分布を課す。

$$\beta_{uk} \sim \text{Gamma}(a_0, b_0), \quad \theta_{kv} \sim \text{Gamma}(c_0, e_0), \quad (4)$$

ここで e_0, a_0 は形状母数、 c_0, b_0 は尺度母数である。ガンマ事前分布は潜在行列の各要素に対する非負制約に対応する。交通

流は負の値を取らないため、この制約は現実に即している。式 (3), (4) の双線形ポアソン分布のベイズ的定式化により、確率的分変推論 [27] 等のベイズ推論の適用が可能になる。推論の方法については次節で詳しく述べる。

ベースライン手法の枠組みでは、曜日だけでなく予測を行う地点周辺のイベント、電車情報等の外部情報を用いて共変量ベクトル $\mathbf{d}_{i,r}$ を構成している。本研究では外部情報を使う代わりに潜在パターン $\{\beta_k^\top \theta_k, K = 1, \dots, K\}$ の混合で交通流を記述する。

$$\lambda_{i,r} = \sum_{k=1}^K \exp(\alpha_k^r) \sum_{u,v} d_{i,r}^u \beta_{uk} \theta_{kv} t_{i,r}^v, \quad (5)$$

ここで α_k^r は混合係数である。このモデルは、複数の道路における交通流データを周期パターンを表す潜在因子の混合で記述する。道路ごとに独立な混合重み $\{\alpha_k^r, k = 1, \dots, K, r = 1, \dots, R\}$ により、道路間の差異と捉えることができる。式 (5) において、各道路における交通流は道路間で共有された潜在因子とそれらの同時伝搬で記述される。

3.2 節で述べた通り、事前分析の結果は道路間の時差相関を示唆している。道路間の時差を考慮するため、畳み込み混合手法を使って (5) 式の混合モデルを書き換える。畳み込み混合モデルでは、各道路は周期パターンに対応する潜在因子を共有しており、それぞれの潜在因子は各道路に時差を伴って伝搬する。(5) 式の混合モデルは畳み込みを用いて拡張することができる。

$$\lambda_{i,r} = \sum_{k=1}^K \sum_{m=1}^M \exp(\alpha_{km}^r) \sum_{u,v} d_{i,r}^u \beta_{uk} \theta_{k(v-m)} t_{i,r}^v, \quad (6)$$

ここで α_{km}^r は混合係数、 m は時差である。 M は考慮する時差の個数である。時間差の効果は日ごとの周期パターン $\{\theta_k, k = 1, \dots, K\}$ の畳み込みを用いて表現される。

5.2.1 推論

我々は提案モデルに確率的分変ベイズを適用する。これにより、オンライン学習が可能になる。[29] の手順に従い、提案モデル (畳み込み双線形モデル) の確率的分変ベイズアルゴリズムを導出する。

r 番目の道路における交通流の履歴 $\mathcal{Y} = \{(y_{i,r}, \mathbf{d}_{i,r}, \mathbf{t}_{i,r}) | i = 1, \dots, n\}$ が与えられた時、提案モデル (6) の変分目的関数は次式で書き下せる。

$$\begin{aligned} \ln p(\mathcal{Y}) &= \ln \int p(\mathcal{Y}, B, \Theta) dB d\Theta \\ &\geq \mathbb{E}_q \left[\ln \left(\frac{p(\mathcal{Y}, B, \Theta)}{q(B, \Theta)} \right) \right] \\ &:= \mathcal{F}, \end{aligned} \quad (7)$$

ここで $\mathbb{E}_q[\cdot]$ は $q(B, \Theta)$ についての積分である。ゴールは、 q に関する制約の下で周辺対数有度の下限 \mathcal{F} を最大化することである。 $q(B, \Theta)$ が以下のように分解できるとする。

$$q(B, \Theta) = \prod_{u,k} q(\beta_{uk}) \prod_{v,k} q(\theta_{vk}).$$

一般的に、パラメータの事前分布がガンマ分布に従い、かつデー

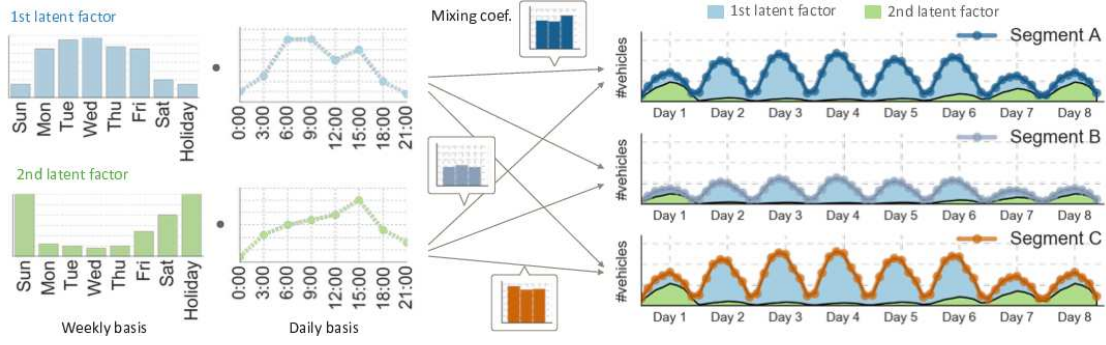


図6 提案法の概略図. 提案法は周期パターンを潜在プロセスとしてモデル化し, 潜在周期パターンを各道路における交通流データから学習する. 各道路の交通流は潜在周期パターンの混合で表される.

々にポアソン分布を仮定している場合, モデルパラメータの q 分布はガンマ分布に従うことが知られている.

$$q(\beta_{uk}) = \text{Gamma}(\beta_{uk} | a_{uk}, b_{uk}),$$

$$q(\theta_{kv}) = \text{Gamma}(\theta_{kv} | g_{kv}, h_{kv}).$$

分解された q 分布の元で, 変分下限 \mathcal{F} を次式で書き換えることができる.

$$\begin{aligned} \mathcal{F} = & \sum_{i=1}^n \sum_{r=1}^R y_{i,r} \mathbb{E}_q[\ln \lambda_{i,r}] - \mathbb{E}_q[\lambda_{i,r}] \\ & + \sum_{k=1}^K \sum_{u=1}^U (\mathbb{E}_q[a_0] - 1) \mathbb{E}_q[\ln \beta_{uk}] \\ & - \sum_{k=1}^K \sum_{u=1}^U \mathbb{E}_q[b_0] \mathbb{E}_q[\beta_{uk}] \\ & + \sum_{k=1}^K \sum_{v=1}^V (\mathbb{E}_q[c_0] - 1) \mathbb{E}_q[\ln \theta_{kv}] \\ & - \sum_{k=1}^K \sum_{v=1}^V \mathbb{E}_q[e_0] \mathbb{E}_q[\theta_{kv}]. \end{aligned} \quad (8)$$

(8) 式の右辺第一項は解析的に解くことができない. そのため, [29] の手順に従いこの項を近似する. イェンセンの不等式を用いて (8) 式の右辺第一項の下界を導出する.

$$\begin{aligned} \mathbb{E}_q[\ln \lambda_{i,r}] & \geq \sum_k \sum_m \sum_{u,v} p_k^{(uv)} \alpha_{km}^r d_{i,r}^u \mathbb{E}_q[\ln \beta_{uk} \theta_{k(v-m)}] t_{i,r}^v \\ & \quad - \sum_k \sum_{u,v} p_k^{(uv)} \ln p_k^{(uv)}, \end{aligned} \quad (9)$$

ここで p_{km}^r は次式で定義される補助パラメータである.

$$p_k^{(uv)} \propto \exp(\mathbb{E}_q[\ln \beta_{uk}] + \mathbb{E}_q[\ln \theta_{k(v-m)}]).$$

(9) 式を (8) 式に置き換えることで, \mathcal{F} に代わる新たな下界を得る. パラメータの分布を求めるため, この下界を $q(\beta_{uk}), q(\theta_{kv})$ について最大化する. 本研究では, 確率的変分ベイズを用いる. 確率的変分ベイズはオンライン学習の一手法であり, パラメータ学習に過去の全てのデータを用いるのではなく, 各々のデータが入ってきた順にリアルタイムで処理する. 最新のデータを素早く反映してモデルパラメータの更新ができるため, 新しいデータが時々刻々としてくるシチュエーションで特に有用である. 本研究では, 週基底 $\{\theta_k, k = 1, \dots, K\}$ を更新した後日基底 $\{\beta_k, k = 1, \dots, K\}$ を一定間隔でオンラインで更新する. $q(\theta_{kv})$ についての平均・分散の更新式は次式で与えられる.

$$g_{kv} = c_0 + \sum_r y_{i,r} \sum_u t_{i,r}^u p_k^{uv} d_{i,r}^v,$$

$$h_{kv} = e_0 + \sum_r y_{i,r} \sum_u \sum_m \exp(\alpha_{km}^r) t_{i,r}^u \mathbb{E}_q[\theta_{k(v-m)}] d_{i,r}^v.$$

$q(\beta_{uk})$ の平均・分散の更新式は次式で与えられる.

$$\begin{aligned} a_{uk}^{(s)} &= (1 - \rho^{(s)}) a_{uk}^{(s-1)} \\ & \quad + \rho^{(s)} \left(a_0 + \frac{V}{|V_s|} \sum_r y_{i,r} \sum_{v \in V_s} t_{i,r}^u p_k^{uv} d_{i,r}^v \right), \\ b_{uk}^{(s)} &= (1 - \rho^{(s)}) b_{uk}^{(s-1)} \\ & \quad + \rho^{(s)} \left(b_0 + \frac{V}{|V_s|} \sum_r y_{i,r} \sum_{u \in V_s} t_{i,r}^u \mathbb{E}_q[\beta_{uk}] d_{i,r}^v \sum_m \exp(\alpha_{km}^r) \right), \end{aligned}$$

ここで (s) は更新回数, $\rho > 0$ はステップ幅 (a.k.a 学習率) である. V_s は学習に使うデータのサブセットである. 実験では $|V_s| = 1$ に固定した.

混合係数の更新には確率的勾配降下アルゴリズムを用いる.

$$\alpha_{km}^r{}^{(s)} = \alpha_{km}^r{}^{(s-1)} + \rho^{(s)} G \nabla_{\alpha_{km}^r} \mathcal{F}_s,$$

$$\frac{1}{G} = \frac{V}{|V_s|} \sum_u \sum_{v \in V_s} \exp(\alpha_{km}^r) t_{i,r}^u \mathbb{E}_q[\beta_{uk}] \mathbb{E}_q[\theta_{k(v-m)}] d_{i,r}^v,$$

ここで \mathcal{F}_s はサブセットデータに対応する \mathcal{F} である. $\nabla_{\alpha_{km}^r} \mathcal{F}_s$ は \mathcal{F}_s の α_{km}^r についての微分であり, 次式で与えられる.

$$\begin{aligned} \nabla_{\alpha_{km}^r} \mathcal{F}_s = & \sum_i \sum_u \sum_{v \in V_s} (y_{i,r} t_{i,r}^u p_k^{(uv)} d_{i,r}^v - \exp(\alpha_{km}^r) \\ & d_{i,r}^u \mathbb{E}_q[\beta_{uk}] \mathbb{E}_q[\theta_{k(v-m)}] t_{i,r}^u). \end{aligned}$$

6. 実験

提案法の予測性能を評価するため, 首都圏エリアで収集した交通流データを用いて実験を行った.

6.1 実験条件

6.1.1 データセット

提案法の予測性能を評価するため, 実際の交通流データを使って実験を行った. 実験で用いたデータは, 2015/4/15 - 5/17 の一ヶ月間, 東京都・神奈川県で GPS 機能付きの携帯電話から収集したものである^(注1). 元のデータは 60 万を超す車の軌跡の集

(注1): NAVITIME 社のカーナビアプリから集めた車のプローブデータを使用した.

合である。各軌跡はタイムスタンプ付きの位置情報 ($id, time, date, latitude, longitude$) の系列である。ここで $time, date$ はそれぞれ id で区別された車が場所 ($latitude, longitude$) で観測された時刻、日にちである。 id は日ごとに別のものが割り振られる。

これらの軌跡を各セグメント、各タイムスロットにおける車の台数に変換する。まず、マップマッチングアルゴリズムを用いて緯度経度の組を道路セグメントに紐付ける: ($id, date, time, r$)。ここで r は道路セグメントのインデックスである。次に、時間を幅 Δt ごとの時間帯に分割し、各時間帯 $v_{i,r}$ 、各曜日 $u_{i,r}$ における r 番目のセグメントの車の台数 $y_{i,r}$ をカウントする: ($y_{i,r}, v_{i,r}, u_{i,r}$)。最後に時間帯と曜日を 1-of-K 表現に変換することで実験に用いるデータセットを得る: ($y_{i,r}, \mathbf{t}_{i,r}, \mathbf{d}_{i,r}$)。

6.1.2 評価基準

以下の二種類の指標を用い、提案手法と既存手法の予測性能を比較した。

$$MAE = \frac{\sum_{i=1}^N \sum_{r=1}^R |y_{i,r} - \hat{y}_{i,r}|}{NR} \quad (10)$$

$$MAPE = \frac{1}{NR} \sum_{i=1}^N \sum_{r=1}^R \frac{|y_{i,r} - \hat{y}_{i,r}|}{y_{i,r}} \quad (11)$$

ここで N は予測を行う地点の数、 R はセグメントの個数である。 $y_{i,r}$ は r 番目の道路の i 番目の交通流で、($\mathbf{b}_{i,r}, \mathbf{t}_{i,r}$) に対応している。 $\hat{y}_{i,r}$ は r 番目の道路の i 番目の予測値である。


1週間から4週間まで、期間の異なる4つの学習データを用意し、それぞれについて学習と予測を行った。予測期間を12 - 48時間後の36時間分とし、全ての実験で期間を固定した(2015/5/16 - 17)。

6.1.3 比較手法


以下の二つの既存手法について、提案手法と予測性能の比較を行った。既存手法として、双線形ポアソン回帰モデルを二通りの設定で用いた。一つ目は、全ての道路のデータに単一の双線形回帰モデルをあてはめる方法(ベースライン1)、二つ目は、各道路で独立に双線形回帰モデルを構築し、別々に学習と予測を行う手法である(ベースライン2)。ベースライン1との比較により、各道路の差異を考慮する必要性を示す。また、ベースライン2との比較により、短期の限られたデータに対する頑健性を示す。

6.2 実験結果

図7は4つの学習データにおける提案手法と既存手法の予測精度を表す。横軸は学習データの期間{1週間, 2週間, 3週間, 4週間}, 図7bの縦軸はMAPE, 図7aの縦軸はMAEである。エラーバーは標準偏差を示す。ベースライン1は全ての期間で他の二手法よりも予測精度が低い。これは、各道路の差異を考慮しないためと考えられる。提案手法は短期の学習データ(1週間, 2週間)において既存手法を上回っている。3週間の学習データに対しては提案手法がベースライン2より低い性能を示しているが、4週間のデータでは提案手法がより良い精度を示す。これらの結果は、複数の道路を包括的にモデリングする手法が、各道路で独立にモデルを構築する方法に比べて短期の限られたデータに対して頑健な予測を与えるということを示している。



(a) MAE



(b) MAPE

図7 4つの学習データ{1週間, 2週間, 3週間, 4週間}における提案手法と既存手法の予測精度。エラーバーは標準偏差を示す。




図8 ベースライン2と提案手法のMAE。12 - 44時間後の予測区間について、2週間の学習データを使った実験結果を示している。

各予測区間における予測性能の評価結果を示す。図8はベースライン2と提案手法のMAEである。12 - 44時間後の予測区間について、2週間の学習データを使った実験結果を示している。提案手法は全ての予測区間において安定した予測性能を示しており、MAEの平均値でベースライン2を下回る。

提案法のもう一つの利点は、解釈しやすい結果を与えることである。全ての道路を同時にモデリングするアプローチは道路ごとに個々のモデルを構築するアプローチよりもシンプルでわかりやすい結果を与える。さらに、NMFは潜在パターンをコンパクトに表現できる。提案手法では、潜在因子は周期パターンを表す。 k 番目の潜在周期パターンは二つのベクトル β_k と θ_k で表される。 θ_k は月曜日から祝日に対応する長さ U の週基底、 β_k は0:00から24:00に対応する長さ V の日基底である。これらの二つのベクトルは複数の道路に共通する周期パターンを表す。例として、図9に二番目の潜在因子 ($k=1$) の日基底と週基底を示す。日基底は10:00周辺でピークを持つ。これは朝のラッシュアワーに対応している。対応する週基底は、平日に比較的高い値を持つ。図10は一番目の潜在因子 ($k=0$) の週基底と日基底である。週基底は日曜日、土曜日、祝日と金曜日に値が立っている。日基底では、19:00に盛り上がりがある。二番目の潜在因子は休日あるいは休前日の帰宅ラッシュを表していると解釈できる。これらの結果は3.2節で報告した基礎分析の結果と一致している。提案手法は掛け算の周期性を捉えることが




図 9 二番目の潜在因子 ($k = 1$) の日基底と週基底. 日基底は 10:00 周辺でピークを持つ. これは朝のラッシュアワーに対応している. 対応する週基底は, 平日に比較的高い値を持つ.




図 10 一番目の潜在因子 ($k = 0$) の週基底と日基底. 週基底は日曜日, 土曜日, 祝日と金曜日に値が立っている. 日基底では, 19:00 に盛り上がりがある. 二番目の潜在因子は休日あるいは休前日の帰宅ラッシュを表していると解釈できる.




図 11 全ての道路における混合係数 $\exp(\alpha_{km}^r)$ ($m = 0$). 交通量は各道路で異なる. 最も交通量が少ないのは道路ネットワークの葉ノードに相当する道路 (E, I, K, N) である. 一方最も交通量が多いのは環状線 A, G である. 放射路線で最も交通量が多いのはセグメント H で, これは東名高速道路に直結しているためと考えられる.

できる.

さらに, 提案手法は道路間の差異を明らかにする. 混合係数は, 各道路における各周期パターンの時差付きの影響を決める. 図 11 に全ての道路における混合係数 $\exp(\alpha_{km}^r)$ を示す. 道路間の差異をわかりやすく示すため, $m = 0$ に固定している. この図からわかるように, 交通量の大きさは各道路で異なる. 最も交通量が少ないのは道路ネットワークの葉ノードに相当する道路 (E, I, K, N) である. 一方最も交通量が多いのは環状線 A, G である. 放射路線で最も交通量が多いのはセグメント H で, これは東名高速道路に直結しているためと考えられる. 図 12 は一番目の潜在因子の混合係数 $\exp(\alpha_{km}^r)$ である ($k = 0$). 網掛けなしのバーが時差なしの係数, 網掛けのバーが 20 分の時差に対応する係数である. 各々の道路セグメントは二つの時差において似た値を示すが, 一部 (セグメント A, G, H) でわずかな違いが見られる. 時差相関をより明示的な形で捉えるために




図 12 一番目の潜在因子の混合係数 $\exp(\alpha_{km}^r)$ ($k = 1$). 網掛けなしのバーが時差なしの係数, 網掛けのバーが 20 分の時差に対応する係数である. 各々の道路セグメントは二つの時差において似た値を示すが, 一部 (セグメント A, G, H) でわずかな違いが見られる.

は, 畳み込みパラメータの事前分布を導入する等の拡張が必要である.

7. 結 論

本稿では, 直近の短期間のデータのみを用い, 複数の道路において長期の予測を行う手法を提案した. 首都圏エリアで収集した交通流データを用いた基礎分析を行い, 掛け算の周期性と道路間の時差相関の存在を確かめた. これらの分析結果に基づき, 直近の短期間のデータのみを用い, 複数の道路において長期の予測を行う新たな手法 (畳み込み双線形ポアソン回帰モデル) を提案した. 提案手法は, 潜在因子モデルを既存の回帰モデルの枠組みに導入することでモデルパラメータの削減を実現し短期間の限られたデータに対しても頑健な予測を行うものである. 提案手法は, 周期パターンを潜在プロセスとしてモデル化し, 各道路における交通流を潜在周期パターンの混合で表現する. 周期パターンを表す潜在プロセスを双線形回帰でモデル化することで掛け算の周期性を考慮することができる. また, 潜在周期パターンを混合する際に畳み込み混合手法を用いることで時差相関を捉える. 本研究では, 提案モデルに確率的変分ベイズを適用し, パラメータのオンライン学習アルゴリズムを導出した. 提案法の利点は下記の通りである. i) 短期のスパースなデータに対しても頑健な予測ができる. ii) 掛け算の周期性, 道路間の時差相関といったデータの中の潜在的な構造を捉え, 明らかにすることができる. iii) 確率的変分ベイズのようなベイズ推論アルゴリズムを適用することができる. これによりオンライン学習が可能になる. 首都圏エリアで GPS 機能付き携帯電話を通して収集した交通流データを用いて実験を行い, 提案手法が従来手法に比べ直近の限られたデータのみを学習に用いた場合により頑健な予測ができることを確認した.

今後は, 時差相関をより明示的な形で捉えるため, 畳み込みパラメータの事前分布を導入する, 畳み込みの代わりに時差そのものに対応するパラメータを導入する等の拡張を検討する.

文 献

- [1] E. Ferguson, *Travel demand management and public policy*, 2000.
- [2] M. Shimosaka, "Forecasting Urban Dynamics with Mobility Logs by Bilinear Poisson Regression," *UbiComp*, pp. 535–546, 2015.
- [3] J. Dauwels, A. Aslam, M. T. Asif, X. Zhao, N. M. Vie, A. Cichocki, and P. Jaillet, "Predicting traffic speed in urban transportation subnetworks for multiple horizons," *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014*, pp. 547–552, 2014.
- [4] H. Tan, Y. Wu, B. Shen, P. J. Jin, and B. Ran, "Short-Term Traffic Prediction Based on Dynamic Tensor Completion," *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 8, pp. 2123–2133, 2016.
- [5] S. Lee and D. Fambro, "Application of subset autoregressive integrated moving average model for short-term freeway traffic volume forecasting," *Transportation Research Record: Journal of the Transportation Research Board*, no. 1678, pp. 179–188, 1999.
- [6] C. Moorthy and B. Ratcliffe, "Short term traffic forecasting using time series methods," *Transportation planning and technology*, vol. 12, no. 1, pp. 45–56, 1988.
- [7] I. Okutani and Y. J. Stephanedes, "Dynamic prediction of traffic volume through kalman filtering theory," *Transportation Research Part B: Methodological*, vol. 18, no. 1, pp. 1–11, 1984.
- [8] Y. Zhang and Y. Liu, "Comparison of Parametric and Non-parametric Techniques for Non-peak Traffic Forecasting," *World Academy of Science, Engineering and Technology*, pp. 8–14.
- [9] G. A. Davis and N. L. Nihan, "Nonparametric regression and short-term freeway traffic forecasting," *Journal of Transportation Engineering*, vol. 117, no. 2, pp. 178–188, 1991.
- [10] C. D. Fabritiis, R. Ragona, and G. Valenti, "Traffic Estimation And Prediction Based On Real Time Floating Car Data," *11th International IEEE Conference on Intelligent Transportation Systems*, pp. 197–203, 2008.
- [11] P. Lingras and P. Mountford, "Time delay neural networks designed using genetic algorithms for short term inter-city traffic forecasting," in *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*. Springer, 2001, pp. 290–299.
- [12] H. Su, L. Zhang, and S. Yu, "Short-term traffic flow prediction based on incremental support vector regression," in *Third International Conference on Natural Computation (ICNC 2007)*, vol. 1. IEEE, 2007, pp. 640–645.
- [13] M. Castro-Neto, Y. S. Jeong, M. K. Jeong, and L. D. Han, "Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions," *Expert Systems with Applications*, vol. 36, no. 3 PART 2, pp. 6164–6173, 2009. [Online]. Available: <http://dx.doi.org/10.1016/j.eswa.2008.07.069>
- [14] B. M. Williams and L. a. Hoel, "Modeling and Forecasting Vehicular Traffic Flow as a Seasonal ARIMA Process: Theoretical Basis and Empirical Results," *Journal of Transportation Engineering*, vol. 129, no. 6, pp. 664–672, 2003.
- [15] W.-C. Hong, "Application of seasonal svr with chaotic immune algorithm in traffic flow forecasting," *Neural Computing and Applications*, vol. 21, no. 3, pp. 583–593, 2012.
- [16] Y. Kamarianakis and P. Prastacos, "Space-time modeling of traffic flow," *Computers and Geosciences*, vol. 31, no. 2, pp. 119–133, 2005.
- [17] M. Van Der Voort, M. Dougherty, and S. Watson, "Combining Kohonen maps with ARIMA time series models to forecast traffic flow," *Transportation Research Part C: Emerging Technologies*, vol. 4, no. 5, pp. 307–318, 1996.
- [18] W. Min, L. Wynter, and Y. Amemiya, "Road Traffic Prediction with Spatio-Temporal Correlations Road Traffic Prediction with Spatio-Temporal Correlations," *IBM Research Report*, vol. 24275, pp. RC24275 (W0706–018) June, 2007. [Online]. Available: <http://domino.watson.ibm.com/library/CyberDig.nsf/home>
- [19] A. Stathopoulos and M. G. Karlaftis, "A multivariate state space approach for urban traffic flow modeling and prediction," *Transportation Research Part C: Emerging Technologies*, vol. 11, no. 2, pp. 121–135, 2003.
- [20] E. I. Vlahogianni, M. G. Karlaftis, and J. C. Golias, "Optimized and meta-optimized neural networks for short-term traffic flow prediction: a genetic approach," *Transportation Research Part C: Emerging Technologies*, vol. 13, no. 3, pp. 211–234, 2005.
- [21] S. Ishak, P. Kotha, and C. Alecsandru, "Optimization of Dynamic Neural Network Performance for Short-Term Traffic Prediction," *Transportation Research Record*, vol. 1836, no. 1, pp. 45–56, 2003.
- [22] H. Tan, G. Feng, J. Feng, W. Wang, Y. J. Zhang, and F. Li, "A tensor-based method for missing traffic data completion," *Transportation Research Part C: Emerging Technologies*, vol. 28, pp. 15–27, 2013.
- [23] H. Tan, G. Feng, J. Feng, W. Wang, Y.-J. Zhang, and F. Li, "A tensor-based method for missing traffic data completion," *Transportation Research Part C: Emerging Technologies*, vol. 28, pp. 15–27, 2013.
- [24] H. Tan, J. Feng, Z. Chen, F. Yang, and W. Wang, "Low multilinear rank approximation of tensors and application in missing traffic data," *Advances in Mechanical Engineering*, vol. 6, p. 157597, 2014.
- [25] H. Tong and C. Lin, "Non-Negative Residual Matrix Factorization with Application to Graph Anomaly Detection." *Sdm*, pp. 143–153, 2011. [Online]. Available: <http://epubs.siam.org/doi/abs/10.1137/1.9781611972818.13>
- [26] Y. Han and F. Moutarde, "Analysis of Large-scale Traffic Dynamics using Non-negative Tensor Factorization," *arXiv preprint*, pp. 1–12, 2012.
- [27] M. D. Hoffman, D. M. Blei, C. Wang, and J. Paisley, "Stochastic Variational Inference," vol. 14, pp. 1303–1347, 2013.
- [28] A. T. Cemgil, "Bayesian inference for nonnegative matrix factorisation models," *Computational Intelligence and Neuroscience*, vol. 2009, 2009.
- [29] J. Paisley, D. Blei, and M. Jordan, "Bayesian nonnegative matrix factorization with stochastic variational inference," *Handbook of Mixed Membership Models and Their Applications*, no. Mcmc, pp. 205–224.