

都市交通分野等に利活用できる リアルタイムモバイルデータの開発

柴崎 真理子¹・薄葉 康生²・高山 知拓³・Chen Quanjun⁴・高安 洋⁵

¹LocationMind 株式会社 (〒101-0048 東京都千代田区神田司町 2-8-1)

E-mail: mariko_shibasaki@locationmind.jp

²LocationMind 株式会社 (〒101-0048 東京都千代田区神田司町 2-8-1)

E-mail: usuba@locationmind.jp (Corresponding Author)

³LocationMind 株式会社 (〒101-0048 東京都千代田区神田司町 2-8-1)

E-mail: takayama@locationmind.com (Corresponding Author)

⁴LocationMind 株式会社 (〒101-0048 東京都千代田区神田司町 2-8-1)

E-mail: q-chen@locationmind.com (Corresponding Author)

⁵東京大学空間情報科学研究センター, 東日本旅客鉄道株式会社 (〒151-0053 東京都渋谷区代々木 2-2-2)

E-mail: mailto:h-takayasu@jreast.co.jp (Corresponding Author)

コロナ禍を機に、従来流通していた画一的な集計データに加えてリアルタイムに処理されるモバイルビッグデータの利活用に着目が集まっている。本研究では、リアルタイムなモバイルビッグデータを都市交通や防災など社会公益サービスに実装するために必要な技術要素や信頼性に対応した人流データ生成のシステムの開発に取り組んでいる。本稿はシステムの実装を通じて人流データ生成処理の技術要素およびシステムによる可視化事例を取り上げる。同時に人流データの信頼性の評価事例として、実測した道路単位の歩行者交通量および駅間旅客数との比較結果を報告する。これらの評価事例から人流データの信頼性が担保されることを考察する。

Key Words: *real-time processing, mobile big data, people flow, urban transportation, disaster risk management*

1. 背景

世界的な COVID-19 の流行から、人の移動やモノの動きに関するデータに注目が集まった。現在、都市交通分野においては、モバイルビッグデータ（昨今は人流データと称す）の活用が一般的になりつつある。例えば台風通過時における交通実態を、事象の数か月後に発生前後のデータを分析し、今後の対策を講じたり、数年先の交通需要の予測に利用したりすることが主な用途となっている。このような事例では集計化された静的なデータが利用されている。

このとき、リアルタイムに人流やモノの移動を把握することができるようになると、周辺環境で発生した事象に関するデータや環境データおよび複数のモバイルデータを、継続的に時系列に重ね合わせることによる解析の高度化および予測などの学習モデルの構築が可能となる。

またリアルタイムな情報発信サービスと組み合わせた意思決定支援サービスの設計も可能となる。

このようにリアルタイム人流データおよび物の移動データは防災分野¹⁾ および BCP 策定支援など様々な分野や人間の意思決定支援への活用を模索されつつある。したがって、リアルタイムな人流データの用途開発への期待が大きく、データ流通のための要件を明らかにして技術開発を進めていく必要があると言える。

2. 目的

本研究では、リアルタイム人流データおよびモノの移動データを流通させることができる場合、求められる技術要素、信頼性や有用性を議論する。そして人流データの活用のケーススタディを通じて有用性を評価する。以

下、本稿の構成を示す。

(1) リアルタイムデータの技術要素

リアルタイムに人流データを処理するための技術要素と仕様を議論する。

(2) リアルタイム人流データシステムの開発と実装

継続的かつ信頼性の高いデータ解析を可能とする処理の仕様と性能を論じる。

(3) リアルタイム人流データの有用性の評価

リアルタイムな人流サービスの実現に必要な技術要素を開発・評価する。人流データ、特に道路リンクや鉄道リンクに結び付いたデータのケーススタディを通じて有用性を評価する。

3. リアルタイム人流データの技術要素

(1) モバイル GPS データの仕様

モバイル GPS データは多様であるが、本研究では、「LocationMind xPop」データを使用した事例を主に取り上げる。（「LocationMind xPop」データは、ゼンリンデータコムが提供するゼンリン地図ナビサービスの利用者より、許諾を得た上で送信される携帯電話の位置情報を、NTT ドコモが総体的かつ統計的に加工を行ったデータである。位置情報は最短 5 分毎に測位される GPS データ（緯度経度情報）であり、個人を特定する情報は含まれない。）図 1 は、人の移動が点データである GPS データの点列としてどのように表現されるのか、移動交通機関などのアノテーションを付与するのかを示している。



図-1 GPS データと人の移動の関連

4. リアルタイム人流データシステムの開発

(1) モバイル GPS データ処理

GPS データはあらかじめ匿名加工されており、図 2 の処理を経て人流データとなる²⁾。

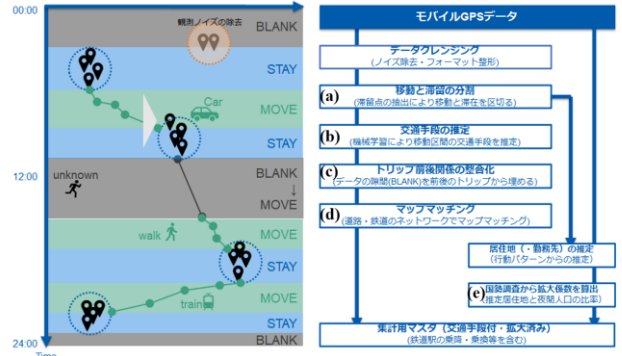


図-2 モバイル GPS データ処理フロー

a) 移動および滞留の分割

GPS データの点データ間の時間と点間距離から一定の閾値を設定し、一連の GPS データ群を「移動 (MOVE)」と「滞在 (STAY)」のグルーピングする。これにより時系列な点データをトリップに分割する。

b) 交通手段の推定

移動—滞在ポイント間の移動速度から交通手段を「歩行」「車」「鉄道」を推定して分類する。交通手段分類する学習データセットを準備し、クラスタリング手法や機械学習に基づく自動分類手法を適用する。

c) トリップ前後関係の整合化

各トリップの前後を比較し、滞留地点間の移動経路がない場合、移動経路を内挿する。

d) マップマッチング

道路ネットワークおよび鉄道ネットワークに沿って点データの位置情報を補正する。利用可能性のある道路や鉄道を移動経路と推定しマップマッチングを行う。マップマッチングにより、道路リンク単位、メッシュ単位、鉄道路線単位の集計が可能となる。

e) 拡大推計

GPS データは全人口（母集団）に対してサンプルデータであるため、再現するための拡大推計処理を実施する。本システムでは、国勢調査などの統計調査と GPS データから算出された夜間人口をもとに拡大係数を算出する。当該拡大係数は分類された集団ごとに決定される。

(2) システム開発

本研究では前項の各処理を経たモバイル GPS データを集計加工し、リアルタイムに人流データを可視化するシステムを実装する。リアルタイム人流データは、現時点

では 15 分毎の提供が可能である。リアルタイム処理システムでは前項に示された基礎処理を実施し、リアルタイム処理集計・予測システムでは、図 3 に示すように滞留人口や交通モード単位、メッシュ単位、道路リンク単位、鉄道ネットワークリンク単位における集計加工処理および可視化が可能となる。

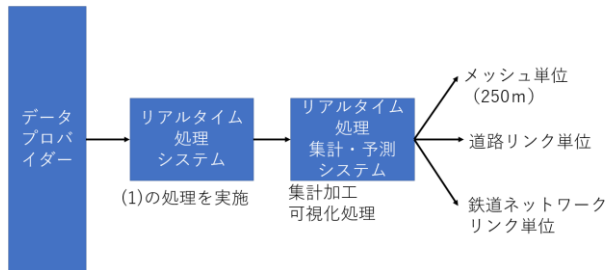


図-3 リアルタイム人流システム構成図

5. リアルタイム人流データのシステム処理事例

(1) 可視化事例

リアルタイム人流データによる可視化事例として、東京 23 区周辺の滞留人口をメッシュ単位 (250m 単位) と道路リンク単位に可視化を実施した事例を図 4 および図 5 にて概説する。この可視化は最短で 15 分ごと人流データが更新される。

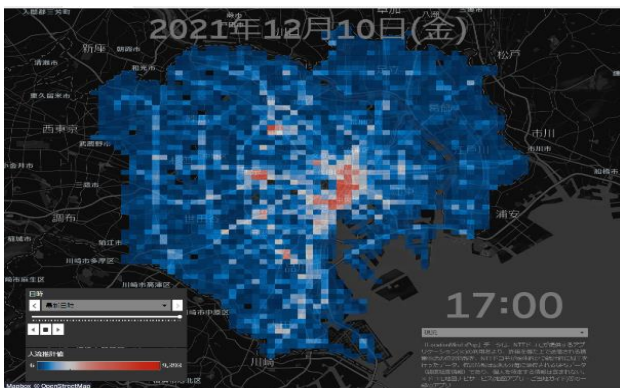


図-4 東京 23 区周辺のリアルタイム人流のメッシュ単位の可視化

(赤い箇所は滞在人口の高密度エリアとなる)
LocationMind xPop © LocationMind Inc.



図-5 東京 23 区周辺の道路リンク上のリアルタイム人流の可視化

(赤い箇所は高密度リンクとなる。徒歩以外に車による移動も含まれる) LocationMind xPop © LocationMind Inc.

(2) リアルタイム人流予測事例

リアルタイム人流の予測は Fan et al. 2018.³⁾によるアンサンブル学習による予測を用いている。これは様々なシナリオやイベントに対応した予測モデルを学習し、適用する予測モデルを、当該時点の実データに適合するように自動選択して予測結果を集合的に生成する手法である。図 6 は Fan et al. 2018 から引用した予測フローの概念図である。シナリオを追加すれば、容易に予測モデル (Predictor) を生成できる。様々なシナリオに適用できることが利点である。そのため大規模災害のような場合にも予測精度の低下を抑えることが可能となる。さらに道路や鉄道などのリンク・ノード毎に人流を予測することも大きな特色である。

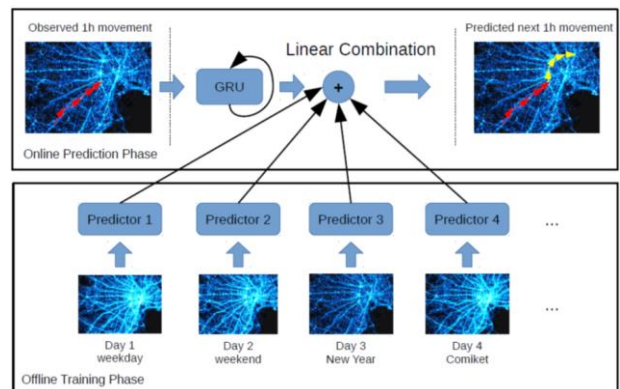


図-6 アンサンブル学習による予測フローの概念図。出典先は Fan et al. (2018)

Fan. et al. 2018 では 60 分先の人流予測が東日本大震災 (2011 年 3 月 11 日) においても可能であることを示している。

また、Jiang et al. 2021⁴⁾ではメッシュベースの予測も可能であることを示している。Jiang et al.2021 では3.11の地震時の人流予測および他の災害が発生したときのメッシュ単位の人流予測結果を比較した。災害やイベント時などの

「異常時」でも、その変化に予測が追従できていることが示されている。

6. リアルタイム人流データの有用性評価

本章ではリアルタイム人流データの有用性評価として、道路リンク単位、鉄道ネットワーク単位の人流データと実際の歩行者交通量および鉄道旅客数を比較する手法を取り上げる。

これら手法に用いられた人流データ（GPS データ）は株式会社ログウォッチャーから提供されたデータである。利用したGPSデータについて、株式会社ログウォッチャー（以下、ログウォッチャー社）が保有しているものであり、データ処理については同社と連携し、GPS 軌跡データを使用した。なお、ログウォッチャー社と共同利用した位置情報では、匿名 ID、タイムスタンプ、経度、緯度のみが収集され、さらに解析結果は集計値の形で得られるため、逆推定による個人の特定は不可能である。

(1) 歩行者交通量との比較

人流データと実測した歩行者交通量の比較検証を行い、リアルタイム人流データの信頼性を評価する方法がある。図7のように歩行者交通量の実測値がある道路ネットワークを抽出した。図8にて Ground Truth として実測値の歩行者交通量と人流データとの比較検証が可能となる。



図-7 比較対象となった道路リンク

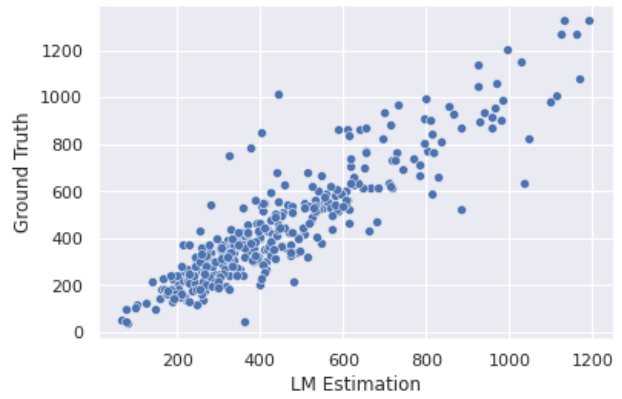


図-8 比較対象となった道路リンクの精度検証結果
人流データはログウォッチャー社から提供

(2) 鉄道旅客数との比較

人流データと鉄道旅客数（駅間の旅客移動数）を比較し、信頼性を評価した手法としては高安ら⁵⁾の既存研究があげられる。高安らは列車荷重（応荷重）データから推定した駅間利用者数を利用し、GPS データからの推定値をキャリブレーションすることを試みた。図9において誤差を加重平均絶対誤差率（WMAPE）で評価すると、夜間人口ベースによる拡大推定は、誤差が 67%から 91%になるのに対し、キャリブレーションを実施すると誤差率は 2%から 10%の範囲に収まる。比較的良好な推定精度が得られることが分かる。

| | 外回り | | 内回り | |
|-------------|----------|-----------|----------|-----------|
| | Baseline | LS_method | Baseline | LS_method |
| 大崎～五反田 | 0.8689 | 0.0271 | 0.7902 | 0.0437 |
| 五反田～目黒 | 0.8795 | 0.0229 | 0.8310 | 0.0316 |
| 目黒～恵比寿 | 0.8926 | 0.0257 | 0.8561 | 0.0320 |
| 恵比寿～渋谷 | 0.9112 | 0.0505 | 0.8573 | 0.0290 |
| 渋谷～原宿 | 0.9010 | 0.0235 | 0.8383 | 0.0210 |
| 原宿～代々木 | 0.9033 | 0.0357 | 0.8455 | 0.0195 |
| 代々木～新宿 | 0.8940 | 0.0214 | 0.8555 | 0.0320 |
| 新宿～新大久保 | 0.8849 | 0.0206 | 0.8084 | 0.0186 |
| 新大久保～高田馬場 | 0.8792 | 0.0332 | 0.8283 | 0.0238 |
| 高田馬場～目白 | 0.8467 | 0.0265 | 0.8350 | 0.0362 |
| 目白～池袋 | 0.8257 | 0.0298 | 0.8404 | 0.0205 |
| 池袋～大塚 | 0.8716 | 0.0237 | 0.8312 | 0.0365 |
| 大塚～池袋 | 0.8771 | 0.0252 | 0.8254 | 0.0269 |
| 池袋～有楽町 | 0.8993 | 0.0485 | 0.8341 | 0.0253 |
| 有楽町～池袋 | 0.8984 | 0.0569 | 0.8375 | 0.0404 |
| 池袋～西日暮里 | 0.8876 | 0.0356 | 0.8449 | 0.0367 |
| 西日暮里～日暮里 | 0.8803 | 0.0576 | 0.8270 | 0.0445 |
| 日暮里～有楽町 | 0.8308 | 0.0401 | 0.8223 | 0.0683 |
| 有楽町～上野 | 0.8181 | 0.0504 | 0.8299 | 0.0491 |
| 上野～御徒町 | 0.8182 | 0.0333 | 0.8612 | 0.0499 |
| 御徒町～秋葉原 | 0.8279 | 0.0373 | 0.8625 | 0.0498 |
| 秋葉原～神田 | 0.7956 | 0.0392 | 0.8305 | 0.0367 |
| 神田～東京 | 0.7921 | 0.0363 | 0.8209 | 0.0408 |
| 東京～有楽町 | 0.7898 | 0.0413 | 0.7798 | 0.0397 |
| 有楽町～新橋 | 0.8073 | 0.0498 | 0.7707 | 0.0479 |
| 新橋～浜松町 | 0.7965 | 0.0539 | 0.7222 | 0.0672 |
| 浜松町～田町 | 0.7742 | 0.0660 | 0.6801 | 0.0644 |
| 田町～高輪ゲートウェイ | 0.7768 | 0.0614 | 0.6748 | 0.0962 |
| 高輪ゲートウェイ～品川 | 0.7718 | 0.0650 | 0.6854 | 0.0834 |
| 品川～大塚 | 0.8743 | 0.0495 | 0.8291 | 0.0313 |

・Baseline = 夜間人口
・LS_method = 最小二乗法
※誤差（比率）は各区間共、1時間単位/日で集計
誤差の大きい区間 (WMAPE>0.1) はなかった。
精度として良好

図-9 山手線における加重平均絶対誤差率（WMAPE）による駅間旅客流動量推定の誤差比較
人流データはログウォッチャー社から提供

7. まとめ

人流データをはじめとするモバイルビッグデータを交通、防災などの社会公益サービスへ応用することは従来幅広く研究・実証されてきた。しかし従来のモバイルビッグデータは後日集計された「オフラインデータ」であり、実際の流動人数等との比較などが行われた例は非常に少ない。またデータプロバイダーから提供されるデータプロダクトも比較的画一的な集計様式に基づいていた。そのため、「全体像を概観すること」には利用できても、ニーズにより即した定量的な分析には十分でない場合も少なくなかった。

またリアルタイムにデータが得られれば、その場その場での意思決定に利用できることから利活用は大きく広がる可能性があるとして期待される。そのために活用方策の検証やサービス実装を、産学連携を通して推進する必要がある。

しかし、実際にリアルタイム処理を実装し、サービスとして運用されてきた実績は少ない。今後は様々な種類のモバイルビッグデータがリアルタイムに提供され、多くの実証検証が社会実装されることが増えると期待される。それに伴い、リアルタイムモバイルビッグデータ（人流データを含む）の品質評価および補正が保証され、信頼性を評価することが求められる。

本研究では、リアルタイム人流データにおいて、技術要素および可視化例を紹介し、データの信頼性に関する検証結果などに関して報告した。

REFERENCES

- 1) 矢部貴大, 関本義秀, 檜山武浩, 金杉洋, 須藤明人: パーティクルフィルタを用いた災害時におけるリアルタイムな人流推定手法, 交通工学論文集, 第2巻, 第2号(特集号A), pp.19-27, 2016. [Yabe, T., Sekimoto, Y., Kashiyama, T., Kanasugi, H. and Sudo, A.: *Real-Time Prediction of People's Movement under Disaster Situations using Particle Filter*, Japan Society of Traffic Engineers, pp.19-27, Vol2, Issue 2(A), 2016.]
- 2) Witayangkurn, A., Haranont, T., Sekimoto, Y. and Shibasaki, R.: Trip reconstruction and Transportation Mode Extraction on Low Data Rate GPS Data from Mobile Phone, *Conference: International Conference on Computers in Urban Planning and Urban Management (CUPUM 2013)*, Utrecht Volume, Article No. 53, 2013.
- 3) Fan, Z., Song, X., Xia, T., Jiang, R., Shibasaki, R. and Sakuramachi, R.: Online Deep Ensemble Learning for Predicting a Citywide Human Mobility, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies archive* Volume 2 Issue 3, 2018
- 4) Jiang, R., Cai Z., Wang, C., Fan, Z., Chen, Q., Tsubouchi, K., Song, X. and Shibasaki, R.: DeepCrowd: A Deep Model for Large-Scale Citywide Crowd Density and Flow Prediction., *IEEE Transactions on Knowledge and Data Engineering*, Volume 35, Issue 1, 2021.
- 5) 高安洋, Xia Tianqi, Jeph Puneet, 金杉洋, 柴崎亮介: GPS データを用いた鉄道利用者の定量的な推定に関する研究, CSIS Discussion Paper No.178, 2023.

DEVELOPMENT OF REAL-TIME MOBILE BIG DATA SYSTEM FOR URBAN TRANSPORTATION AND PUBLIC SERVICES

Mariko Shibasaki, Yasuo USUBA, Tomohiro TAKAYAMA, Quanjun CHEN,
Hiroshi TAKAYASU

The “Corona Disaster” has attracted attention to the utilization of real-time mobile big data, in addition to uniform aggregated and off-line data that has been used for geospatial analysis. In this research, we propose people flow data generation system and address technical elements and reliability required to implement real-time mobile big data analysis for social utility services such as urban transportation and disaster risk management. This paper discusses the technologies behind the real-time people flow data service, examples of visualization and the implementation. At the same time, as an example of evaluating the reliability of the people flow data, we report the results of comparison cases of both pedestrian traffic counts per street and the number of railway passengers between stations. The reliability of human flow data will be discussed based on these evaluation cases.