

逆離散フーリエ変換を用いた新しいエリア特徴量～活性度～の定義

井上 隼英[†] 石田 繁巳^{††,†††} 荒川 豊[†]

[†]九州大学大学院システム情報科学府・研究院 〒819-0395 福岡市西区元岡 744

^{††}九州大学システム LSI 研究センター 〒819-0395 福岡市西区元岡 744

^{†††}公立ほこだて未来大学システム情報科学部 〒041-8655 北海道函館市亀田中野町 116-2

あらまし 地域の特徴ある観光資源を活かした取り組みを効果的に進めるために、観光施策においても EBPM (Evidence-Based Policy Making) を推進することが求められている。筆者らは、位置情報ビッグデータを分析してイベントや観光施策に関連する人流を可視化する地域観光 EBPM 推進プラットフォームの研究開発を行っている。本プラットフォームはイベントを自動的に検知する機構を具備しており、「どこで」「どれくらいの規模で」イベントが実施されているのか自動的に検知した上で、自治体職員などを通じてイベント情報収集を促し、イベントと人流の紐付けを行う。人流変化に基づくイベント検知手法として、外れ値検知を人流データに適用する従来手法が考えられるが、平日・休日の人流の差などの定常的な人流変化を考慮したイベント検知を実現できないという問題がある。これに対し、本稿では非定常的な人流変化の時系列データである「活性度」を定義し、活性度に対してピーク検知を適用することでイベントを検出する手法を提案する。九州大学伊都キャンパスと周辺の地域の位置情報データを用いた評価を行った結果、筆者らの調査した範囲で、検知されたイベントの 3/4 以上で実際にイベントが行われていたことを確認した。

キーワード 合理的根拠に基づく政策立案 (EBPM), 位置情報データ, イベント検知

Definition of a new feature of location activeness using Inverse Discrete Fourier Transform

Shunei INOUE[†], Shigemi ISHIDA^{††,†††}, and Yutaka ARAKAWA[†]

[†] ISEE, Kyushu University

^{††} SLRC, Kyushu University

^{†††} School of Systems Information Science, Future University Hakodate

Abstract It is important to promote Evidence-Based Policy Making (EBPM) to conduct effective tourism policies with unique tourism resources. We are developing an EBPM platform that visualizes people flows relating to events and tourism policies. Our EBPM platform has an automatic event detector that detects “where” and “how large” an event is held. When an event is detected, the platform notifies local government officers and encourages them to enter the event information to link the event and corresponding people flow. Although, we can use anomaly detection methods to detect events from people flow data, these methods take no considerations on periodic changes in people flow. In this paper, a new feature, i.e., location activeness, is defined as time-series people flow data, excluding periodic changes. We also present an event detection method base on peak detection on the location activeness. The evaluation conducted with location data of Kyushu University Ito Campus and surrounding areas demonstrated that more than 75% of detected events were actual events, as we could find out.

Key words Evidence-Based Policy Making (EBPM), Location Data, Event Detection

1. はじめに

少子高齢化など日本の経済社会構造が急速に変化する中、限られた資源を有効に活用し、国民に信頼される行政を展開するための取り組みとして合理的根拠に基づく政策立案 (EBPM :

Evidence-Based Policy Making) の推進が求められている。2015 年の「経済財政運営と改革の基本方針 2015 ～経済再生なくして財政健全化なし～」[1]以降様々な分野で EBPM 推進に向けた取り組みが進められてきた。特に、観光分野では地域の特徴ある観光資源を活かした取組を効果的に進めるために多く

の自治体が EBPM に力を入れている。

地方自治体では観光ビッグデータを活用した動態調査を民間企業に委託し、単年で地域の状態を把握して改善策を導出することに成功している例も報告されている。一方で調査期間、職員業務負荷、予算調達という課題から自治体の施策をすべて検証し、評価結果を蓄積することで施策の精度や説明力を高めていく EBPM モニタリング基盤の構築には至っていない。

このような背景から、筆者らは地域観光 EBPM 推進プラットフォームの研究開発を行っている [2]。本プラットフォームはビッグデータ集計部と分析・可視化部で構成されており、プログウォッチャー社から提供される位置情報データを分析してイベントや観光施策に関連する人流を可視化する。データ提供者であるプログウォッチャー社においてビッグデータ集計部で位置情報データの匿名化と集計とを行った上で位置情報データを提供してもらい、分析・可視化部で位置情報データを分析してイベントの検出とイベントに伴う人流の分析を行う。そして、検出されたイベントと人流の変化とを紐付け、その結果をユーザに提供する。

本プラットフォームの実現に向けては、イベントを自動的に検出する仕組みの実現が重要である。イベントには自治体が関与するものだけではなく、新しい店舗の開店や口コミで広まっているイベント、一部の人々の間で有名な観光スポットで行われる非公式イベントなど、自治体職員や観光協会などが把握していないイベントも存在すると考えられる。このようなイベントの情報を自治体職員などが収集することは困難である。このため、人流データから「どこで」「どれくらいの規模で」イベントが実施されているのかを自動的に検知し、自治体職員などを通じてイベント情報収集を促すことでイベントと人流変化との紐付けを行う。

人流データからイベントを検知する手法としては、人流データに対する外れ値検知などの従来手法が考えられる。しかしながら、外れ値検知によるイベント検知では定常的な人流の変化を考慮したイベント検知を行うことができない。例えば、平日は人が少なく、休日に多くの人々が訪れるショッピングモールでは、平日に比べて人が多い「休日」がイベントとして検知されるが、実際に休日にイベントが行われているかを推定するためには他の休日と人流の変化を比較しなければ分からない。「他の休日」のような比較対象は場所や日時などによって変更する必要があることから外れ値検知によるイベント検知では比較対象を動的に変更する必要がある、大規模なイベント検知の実現は困難である。

これに対し、本研究では非定常的な人流変化の時系列データである「活性度」を定義し、活性度に対してピーク検知を行うことでイベントを検知する手法を提案する。活性度は、離散フーリエ変換 (DFT: Discrete Fourier Transform) により人流変化の周波数分析を行って非定常的な周波数成分を取り出した上で逆離散フーリエ変換 (IDFT: Inverse DFT) することで算出する。活性度はその場所 (エリア) における人流が普段とどれくらい異なる変化をしているのかを表す指標である。イベント検知の対象となる POI (Point of Interest) ごとに活性

度を算出し、活性度、すなわち、非定常的な人流変化の時系列データに対してピーク検知手法を適用することでイベントを検知する。

活性度を用いたイベント検知の有効性を検証するため、九州大学伊都キャンパスやその周辺地域の活性度を算出し、活性度を用いてイベント検知を行った。その結果、筆者らが調査できた範囲で、検知されたイベントの 3/4 以上で実際にイベントが行われていたことを確認した。

本稿の構成は以下の通りである。2. では関連研究について述べ、3. では提案する活性度の定義及び活性度を用いたイベント検出手法を示す。4. で活性度を用いたイベント検出手法の有効性を検証し、最後に 5. でまとめとする。

2. 関連研究

位置情報データを活用した都市のイベント検知の研究としては、マイクロブログサービスなどの投稿を活用する手法が報告されている。代表的な手法として、Twitter においてジオタグと呼ばれる位置情報が付与されたツイートを収集し、地域ごとの投稿件数から地域イベントを検出する手法が報告されている [3], [4]。また、マイクロブログサービスの投稿内容を解析し、イベントの発生と名称などの情報を抽出する手法も提案されている [5]。しかし、位置情報を付与したマイクロブログ投稿は減少しており、位置情報が付与されたマイクロブログ投稿を得ることは難しくなりつつある。

人流データを用いたものには木南らの災害や事故、混雑などの社会的混乱検知システムなどがある [6]。他にもタクシーのトリップデータなどの交通流データを用いたもの [7] やカメラの映像を用いて都市の異常を検知する手法 [8] が提案されている。

人流や交通流データを分析する際は外れ値に注目して、人流や交通流の異常を検出する。

人流や交通流などのデータのための外れ値検知の手法には統計モデルを用いた方法や、類似性に基づくアプローチなどがある [9]。統計的アプローチには Ngan ら [10], Kingan ら [11] の手法があり、これらは正常なデータは何らかの統計的モデルに従うと仮定し、そのモデルから外れたデータを外れ値として異常を識別している。類似性に基づくアプローチには Dang ら [12], Tang ら [13] の手法があり、これらは k 最近傍法や局所外れ値因子法などを用いて局所密度を近傍と比較することで異常スコアを算出し異常を識別している。これらのアプローチではデータの周期的な変化は考慮されておらず、周期性に埋もれたイベントを検知するのが難しいと考えられる。

本研究では人流変化の周期性に注目し、時系列人流データから周期的変化を除去して得られる特徴量の活性度データを用いてイベントを検知する。提案手法では周期的な変化に埋もれ、外れ値的な人流にならなかったイベントを検知することも可能である。

3. 活性度及び活性度を用いたイベント検出

3.1 活性度の定義

活性度は、非定常的な人流変化を示した時系列データである。




図 1: 九州大学伊都キャンパスウエストゾーンの流入人口の変化

活性度は場所ごと、時刻ごとに定義され、その場所の流入人口の変化の周期性を分析し、周期的な成分を除去することで非定期的な人流変化のみを抽出する。

活性度を用いれば、場所（エリア）ごとに独特な人流の周期性を考慮して、人流の変化を分析することができる。例えば、大学などの学校が含まれる場所では平日に人が多く、休日になると人が少なくなることから、1週間という周期で人流の変化を観測できる。このような周期性は、その場所に含まれる施設や土地の利用形態によって定まることから、周期性はその場所を表す特徴量の一つと言える。

図 1 に、2019 年の九州大学伊都キャンパスウエストゾーンにおける流入人口の変化を示す。図より、九州大学伊都キャンパスウエストゾーンにおいては平日に流入人口が多く、休日になると流入人口が少なくなるとい、周期性のある人流変化を確認できる。九州大学伊都キャンパスウエストゾーンは主に理系学生が通う地区である。多くの実験棟や研究施設があり、平日は講義や実験などが行われている。講義や実験などが平日に行われることから 1 週間の周期で人流が変化していると考えられる。

一方で、図 1 の例では 4 月下旬から 5 月上旬にかけて周期性が崩れていることが確認できる。これは、ゴールデンウィークという連休によって人流が減少したためと考えられる。人流変化にはその地点の特徴を表す周期的な変化が含まれる一方で、休日の変化やイベントなどにより周期性に乱れが生じる。このような周期性の乱れを活性度から抽出することでイベントを検知することが可能となる。

3.2 活性度の算出

図 2 に活性度算出の概要を示す。活性度の算出は、DFT ステップ、周期除去ステップ、IDFT ステップの三つのステップで構成される。人流の周波数スペクトルを計算し、支配的な周波数成分を除去することで非定期的な人流変化を得る。

まず、DFT ステップにおいて人流スペクトルを計算する。人流スペクトルは、人流データの振幅スペクトルである。人流データは一定時間ごとの離散的な時系列データであることから、




図 2: 活性度算出の概要




図 3: DFT ステップで得られた人流スペクトルの例

データ点数 N の時間窓でデータを取り出して窓関数を乗じた上で離散フーリエ変換 (DFT) を適用することで、人流スペクトルを得る。窓関数にはハミング窓を用いる。

図 3 に、DFT ステップで得られた人流スペクトルの例を示す。図は、図 1 に示した人流データの先頭から時間窓幅 $N = 256$ を取り出して人流スペクトルを算出した結果を示している。図の横軸は周波数であるが、周波数の単位である Hz を用いると非常に小さい値となって表記に支障をきたすことから、本稿では「1日に1回という振動数」を dayHz と定義し、人流スペクトルは dayHz を用いて表記する。図 1 の人流データのサンプリング周期は 1 日であることから、標本化定理より、最大で 0.5 dayHz まで周波数の人流スペクトルを観測することができる。

図 3 では 0.1445 dayHz 及びその高調波にピークがあることが確認できる。0.1445 dayHz はおよそ 7 日間周期の変化に相当することから、3.1 で示した 1 週間、すなわち 7 日間周期の人流変化を抽出できていることがわかる。

周期除去ステップでは DFT ステップで得られた人流スペクトルを二乗して人流パワースペクトルに変換した上でピーク検知を適用し、ピークとなった周波数成分を除去することで人流変化の周期的な成分を除去する。まず、DFT ステップで得られた人流パワースペクトルにピーク検知を適用し、ピークが大きい順に並べ替える。次に、ピークの大きいものから順に、人流パワースペクトルのピークに対応する人流スペクトルの成分をゼロにして、ピーク成分を除去する。ピーク成分の除去は、直流成分を除いた全エネルギーに対して除去したピークに対応する人流パワースペクトルのエネルギー割合が周期成分除去率 $T[\%]$ を超えるまで行う。

最後に、IDFT ステップにおいて、周期除去ステップで周期的な成分を除去した人流スペクトルを逆離散フーリエ変換 (IDFT) し、窓関数で除することで活性度のデータを算出する。




図 4: 九州大学伊都キャンパスウエストゾーンの活性度の変化

図 4 に、活性度の例を示す。図は、図 1 の先頭から時間窓幅 $N = 256$ のデータを取り出して活性度を算出した結果を示している。周期成分除去率は $T = 40\%$ とした。図 4 より、図の中央部分では周期的な変化が小さくなっていることが確認できる。所々に活性度のピークが存在しており、非周期的な人流変化が発生したことを示している。上に凸なピークは定常時よりも多くの人流が発生したことを、下に凸なピークは定常時よりも人流が少なかったことを示している。期間の両端付近は元の図 1 とほぼ同じ変化を示している。これは、窓関数の影響により期間の両端付近で周期的な成分を除去しきれなかったためと考えられる。

3.3 活性度を使ったイベント検知

イベントの検知は、活性度の時系列データに対してピーク検知を適用することで行う。図 4 のような活性度の時系列データにピーク検知を適用し、突発的な人流変化によって発生するピークを検知することでイベントを検知する。本研究で研究開発を行っている地域観光 EBPM 推進プラットフォームは通常よりも人流が増加するイベントを対象としていることから、上に凸なピークのみを検知の対象とする。

本研究では、ピーク検知の手法は限定しない。時系列データに対する一般的なピーク検知手法や、2. に示したような外れ値検知手法を活性度の時系列データに適用する。

本稿ではピーク検知の手法の一例として、移動窓に対して Hampel Identifier [14] を適用した。Hampel Identifier は外れ値検知で広く用いられている 3σ 法の一つであり、外れ値に対してロバストな統計的外れ値検知手法である。 3σ 法と同様に広く用いられているシンプルで古典的な外れ値検知手法である。活性度の時系列データの中のある点に着目し、その前後 k 点の合計 $2k + 1$ 点を取り出して中央値と中央絶対偏差を求める。そして、着目している活性度の点と中央値との差が中央絶対偏差の 3 倍より大きければピークであるとする。移動窓と Hampel Identifier を用いたピーク検知では活性度データから移動窓でデータを抽出し、中央値と中央絶対偏差を求め、それらを活性度と比較してピークを検知する。パラメータ k は経験的に 3 から 5 で良いとされていることから [15]、本稿では $k = 5$ とした。

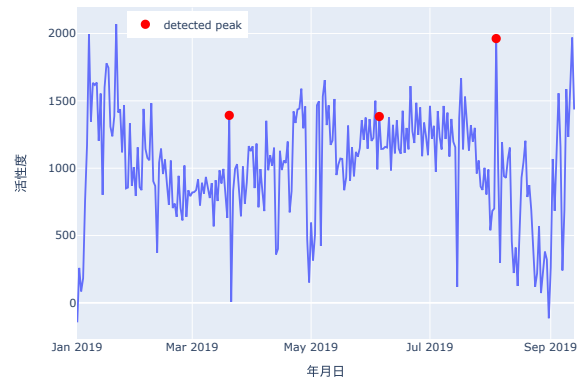


図 5: 活性度を用いた九州大学伊都キャンパスウエストゾーンにおけるイベント検知結果の例

図 5 に活性度を用いたイベント検知結果の例を示す。図より、上に凸な複数のピークが検知されていることがわかる。

4. 評価

活性度を用いたイベント検知の有効性を検証するため、九州大学周辺の位置情報データを用いて周期成分除去精度及びイベント検知の評価を行った。なお、DFT ステップ、IDFT ステップでは時間窓幅 N を 2 のべき乗として離散フーリエ変換、逆離散フーリエ変換の代わりに高速フーリエ変換 (FFT: Fast Fourier Transform)、逆高速フーリエ変換 (IDFT: Inverse FFT) をそれぞれ用いた。また、筆者らが研究開発を行っている地域観光 EBPM 推進プラットフォームではブログウォッチャー社から提供された位置情報ビッグデータを用いるが、十分な長さのデータが収集されていないことから株式会社 NTT ドコモのモバイル空間統計データを用いて評価を行った。

4.1 位置情報データ

評価には株式会社 NTT ドコモのモバイル空間統計データ^(注1)を、地域観光 EBPM 推進プラットフォームで使用している人流データの形式に変換して使用した。モバイル空間統計は地域メッシュコードの $1/2$ メッシュコード (500 [m] × 500 [m] メッシュ) 単位で、1 時間毎に滞在人口の推計値を取得することができる。このデータを、メッシュごとに 1 日に流入した人口に変換した。具体的には午前 0 時から 6 時までの人口の平均を夜間人口とし、1 日の最大人口から夜間人口を引いた値を流入人口として人流データを得た。流入人口が負の値になった場合は 0 とした。

4.2 周期成分除去精度の評価

周期成分除去精度の評価では 4.2 に示した周期除去ステップで除去された周期の精度について評価した。

本評価では、九州大学伊都キャンパスウエストゾーンとセンターゾーン、九大学研都市駅が含まれるメッシュの 2019 年のデータを対象とした。これらの地点では平日に流入人口が多く、休日に流入人口が少なくなる傾向があり、おおよそ 7 日間周期

(注1): <https://mobaku.jp/>




図 6: 九大学研都市駅の流入人口の変化

表 1: 周期成分除去精度

地点	時間窓幅 N		
	64	128	256
九州大学伊都キャンパス ウエストゾーン	100%	100%	100%
九州大学伊都キャンパス センターゾーン	100%	100%	100%
九大学研都市駅	100%	100%	100%

で人流が変化している。九州大学伊都キャンパスウエストゾーンとセンターゾーンは教職員・学生が多く通う地区で多くの実験棟や研究施設があり、平日は講義や実験などが行われている。図 1 に示したように、7 日間周期で人流が変化している。また、図 6 は九大学研都市駅の 2019 年の流入人口の変化を示している。九州大学伊都キャンパスとは逆に平日に流入人口が少なく休日に流入人口が多くなる傾向があるが、7 日間周期で人流が周期的に変化していることがわかる。

各メッシュの人流データを時間窓幅 N で取り出し、3.2 に示した DFT ステップ及び周期除去ステップの処理を行って人流変化の周期的成分が除去されたかどうかを記録した。この操作を人流データの取り出し位置を移動させながら繰り返し、周期成分除去が正しく行われた割合を周期成分除去精度として評価した。時間窓幅 N を 64, 128, 256 と変化させ、人流データの取り出し位置を 2019 年 1 月 1 日から 1 日ずつシフトさせて 1 地点につき周期成分除去を $365 - N + 1$ 回繰り返した。周期成分除去率 T は、事前に行った予備実験の結果から $T = 40$ [%] とした。

表 1 に周期成分除去割合の評価結果を示す。表に示す通り、時間窓幅 $N = 64$ から $N = 256$ まですべての地点において周期成分除去精度は 100% であった。時間窓幅や地点の影響は確認できなかった。取り出す時間窓幅 N が周期に比べて標本化定理の観点で十分に長ければ人流変化の周期性を抽出することが可能であり、周期的な成分の除去を容易に実現できたとと言える。

4.3 イベント検知の評価

イベント検知の評価では、活性度を用いて検知したイベントの日付・地点で実際にイベントが行われていたかを調査した。

表 2: 九州大学伊都キャンパスウエストゾーン

検知された日付	イベントの調査結果
2019 年 3 月 20 日	卒業式
2019 年 6 月 5 日	不明
2019 年 8 月 4 日	オープンキャンパス
2019 年 10 月 2 日	後期授業開始

実際に行われたイベントをすべて調査することは不可能であるため、イベントを網羅的に検知できたかを評価することができない。このため、本評価においては検知されたイベントの日付で実際にイベントが行われていたかを調査し、イベントの実施を確認できなかった場合はイベントの有無は不明であるものとした。

九州大学伊都キャンパスウエストゾーンと九大学研都市駅の 2019 年の活性度を算出し、3.3 に示したイベント検知手法を活性度に適用してイベントを検知した。検知されたイベントの日付、地点で実際にイベントが行われていたかどうかをインターネット上の情報で筆者らが手動で調査した。

活性度の算出では時間窓幅 $N = 256$ とした。2019 年 1 月 1 日から 12 月 31 日までの人流データを 2019 年 1 月 1 日から 9 月 13 日まで、4 月 20 日から 12 月 31 日までの 2 つの時間窓でそれぞれ活性度を算出した。2019 年 4 月 20 日から 9 月 13 日までは 2 つの時間窓で共通していることから、それぞれの時間窓でイベント検知を行い、いずれかの時間窓でイベントが検知されたときにイベントが検知されたとした。

表 2 及び表 3 に、九州大学伊都キャンパスウエストゾーン及び九大学研都市駅におけるイベント検知結果をそれぞれ示す。イベント調査結果が「不明」となっているものは、筆者らがイベントを特定できなかった場合を示している。

表 2 に示すように、九州大学伊都キャンパスウエストゾーンの活性度から 4 個のイベントが検知された。そのうち 3 個については筆者らが調査した範囲でイベントなどが実際に行われていたことを確認した。2019 年 3 月 20 日は春休み期間中の平日であり、卒業式によって前後の日付の人流と比較すると多くの人流が観測されていた。2019 年 8 月 4 日は前期間中の土曜日であり、オープンキャンパスが開催されていた。流入人口は前後の日付の平日と同程度だったが、普段の土曜日と比較するとかなり多くの人流が記録されていた。2019 年 10 月 2 日は平日であり、後期授業の開始日であった。2019 年 6 月 5 日は前期間中の平日の水曜日であるが、筆者らの調査した範囲ではイベントを確認できなかった。

九州大学伊都キャンパスウエストゾーンの流入人口を示した図 1 を参照しても、2019 年 8 月 4 日にピークを確認することはできない。オープンキャンパスが開催された 2019 年 8 月 4 日の人流は、8 月 4 日付近の日付の人流と比較しても特別に多いわけではなく、平日と同程度の人流が記録されていた。しかしながら、8 月 4 日は土曜日であり、他の土曜日に比べて人流が増加していることがわかる。活性度を用いることで「土曜日は人が少ない」という周期性を考慮してイベント検知を行うことが可能となり、オープンキャンパスというイベントを検知でき

表 3: 九大学研都市駅

検知された日付	イベントの調査結果
2019年1月14日	成人の日
2019年3月21日	春分の日
2019年3月24日	不明
2019年7月15日	海の日
2019年8月17日	花火大会
2019年9月23日	秋分の日
2019年10月12日	不明
2019年10月14日	体育の日
2019年10月22日	即位礼正殿の儀が行われる日
2019年11月04日	文化の日の振替休日

たと言える。

また、図1で人流の大きな変化を確認できる2019年3月20日の卒業式、10月2日の後期授業開始のようなイベントも活性度算出の影響を受けることなく検知できることがわかる。

表3に示すように、九大学研都市駅の活性度からは10個のイベントが検知された。そのうち8個については筆者らが調査した範囲でイベントなどが実際に行われていたことを確認した。検知される「イベント」は人流の大きな変化であるため、不定期な祝祭日の影響による人流変化もイベントとして検知される。表3ではこのような祝祭日の影響も筆者らの調査した「イベント」に含めた。検知された10個のイベントのうち、7個は祝祭日であった。2019年8月17日は土曜日であり、九大学研都市駅の近隣で花火大会が開催されていた。この日は普通の休日の2倍以上の人流が記録されていた。

九大学研都市駅の流入人口を示した図6を参照すると、2019年8月17日に突出したピークを確認できる。このような大きな人流変化は、活性度算出の影響を受けることなく検知できた。

本稿で提案する活性度を用いる手法では、祝祭日のような不規則的な人流変化の影響を除去することはできない。九大学研都市駅は平日に流入人口が少なく休日に流入人口が多くなる傾向がある。祝祭日などで平日が休日になると流入人口は休日並になり普通の平日より多くなるので、人流変化の周期性に乱れが生じ、イベントとして検知された。祝祭日情報はカレンダーから取得することができることから、カレンダーと照らし合わせるなど、イベント検知手法には改良の余地があると言える。

5. おわりに

本研究ではEBPM推進プラットフォームにおいて人流データと観光施策を紐付けるために必要なイベント検知手法を提案した。本手法では人流データから周期的変化を除去して得られた新たなエリア特徴量を活性度を定義し、活性度のピークを検知することでイベントの発生した可能性のある日を特定した。提案手法を九州大学伊都キャンパスとその最寄り駅で評価した結果、周期性に埋もれていたイベントを検知することができたが、祝祭日も検知してしまうことがわかった。今後はさらに多くのエリアに本手法を適用し、実際に起きたイベントと検知されたイベントを比較して定量的な評価を実施し、イベント検知の精度を検証していく。

謝辞 本研究成果の一部は、国立研究開発法人情報通信研究機構の委託研究及び国立研究開発法人科学技術振興機構のセンサー・オブ・イノベーション (COI) プログラム, JPMJCE1318の支援により得られたものである。

文 献

- [1] “内閣府（経済財政諮問会議）：経済財政運営と改革の基本方針 2015～経済再生なくして財政健全化なし～,” <https://www5.cao.go.jp/keizai-shimon/kaigi/cabinet/2015/decision0630.html>, 2015.
- [2] 荒川 豊, 石田繁巳, 酒井幸輝, 峯 恒憲, “大規模広告位置データによる観光施策立案評価システムの設計,” 情報処理学会研究報告, MBL 研究会, pp.1–6, May 2021. MBL-99-29.
- [3] C. Zhang, G. Zhou, Q. Yuan, H. Zhuang, Y. Zheng, L. Kaplan, S. Wang, and J. Han, “Geoburst: Real-time local event detection in geo-tagged tweet streams,” Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp.513–522, SIGIR '16, Association for Computing Machinery, New York, NY, USA, 2016.
- [4] R. Lee and K. Sumiya, “Measuring geographical regularities of crowd behaviors for twitter-based geo-social event detection,” Proceedings of the 2nd ACM SIGSPATIAL International Workshop on Location Based Social Networks, pp.1–10, LBSN '10, Association for Computing Machinery, New York, NY, USA, 2010.
- [5] 山田 涉, 菊地 悠, 落合桂一, 鳥居大祐, 稲村 浩, 太田 賢, “マイクロブログを用いたイベント情報抽出技術,” 情報処理学会論文誌, vol.57, no.1, pp.123–132, Jan. 2016.
- [6] Y. Kinami, T. Shibuya, S. Toride, and Y. Endo, “A fundamental study of social confusion detection system by machine learning using human flow data,” Proceedings of the Fuzzy System Symposium, vol.36, pp.431–436, 2020.
- [7] H. Zhang, Y. Zheng, and Y. Yu, “Detecting urban anomalies using multiple spatio-temporal data sources,” Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, vol.2, no.1, pp.1–18, 2018.
- [8] M. Sabokrou, M. Fayyaz, M. Fathy, Z. Moayed, and R. Klette, “Deep-anomaly: Fully convolutional neural network for fast anomaly detection in crowded scenes,” Computer Vision and Image Understanding, vol.172, pp.88–97, 2018.
- [9] Y. Djenouri and A. Zimek, “Outlier detection in urban traffic data,” Proceedings of the 8th International Conference on Web Intelligence, Mining and Semantics, pp.1–12, WIMS '18, Association for Computing Machinery, New York, NY, USA, 2018.
- [10] H.Y. Ngan, N.H. Yung, and A.G. Yeh, “Outlier detection in traffic data based on the dirichlet process mixture model,” IET intelligent transport systems, vol.9, no.7, pp.773–781, 2015.
- [11] R.J. Kingan and T.B. Westhuis, “Robust regression methods for traffic growth forecasting,” Transportation research record, vol.1957, no.1, pp.51–55, 2006.
- [12] T.T. Dang, H.Y. Ngan, and W. Liu, “Distance-based k-nearest neighbors outlier detection method in large-scale traffic data,” 2015 IEEE International Conference on Digital Signal Processing (DSP)IEEE, pp.507–510 2015.
- [13] J. Tang and H.Y. Ngan, “Traffic outlier detection by density-based bounded local outlier factors,” Information Technology in Industry, vol.4, no.1, pp.6–18, 2016.
- [14] F.R. Hampel, “The influence curve and its role in robust estimation,” Journal of the american statistical association, vol.69, no.346, pp.383–393, 1974.
- [15] R. Pearson, “Scrub data with scale-invariant nonlinear digital filters,” EDN, vol.47, no.2, pp.71–78, Jan 24 2002.