

イベント告知情報と大規模言語モデルに基づく イベント会場周辺の早期群衆混雑予報

安納 爽響¹ 坪内 孝太² 下坂 正倫¹

概要: お祭りや花火大会といった公共イベント下において、会場周辺の人混み具合を予報しておくことは、安全上・モビリティの快適性の観点から重要な話題である。既存の混雑予報手法は、イベント会場における過去の群衆動態に基づいて予報を行うが、イベントの内容による来訪者数の違いを捉えることはできない。イベントの内容を考慮して来訪者数を精緻に予報するために、イベントの告知情報に着目する。大規模言語モデル (LLM) を用いて、テキスト形式で与えられる告知を整形・特徴量化し、イベント下の群衆動態のモデリングに使用することを提案する。実際の人流ログデータ、イベントの告知情報を用いて、東京周辺の 24 会場 305 個のイベントに対して、予測手法の性能評価を行う。実験結果より、イベントの内容を考慮することで、イベント間の人出の違いを精緻に予報することが可能となったことが示された。

1. 序論

都市における人混みの予報は、安全性・モビリティの快適性といった観点から重要な話題である。特に公共の催し物 (花火大会、お祭りなど) は会場周辺の人混みを誘発しやすい。そういったイベントがどの程度の人々でごった返すのかを事前に把握しておくことは、催し物の計画をする主催者、雑踏警備を行う行政当局、来訪者や周辺住民など、都市において生活を営む全ての人にとって有益である。しかし、数時間先の人混みをシミュレーション的に予測する枠組み [6], [8], [10] は存在するが、こういった短期的な未来の予測は、混雑時の状況を推測し適切に警備員を配置するといった観点からは不十分である。

したがって、実応用上の側面からは、人混みを早期に予報することが重要である。人混みの早期予報はこれまで、外的要因に基づいた予報が提案されている。特に、乗換検索アプリ上のルート検索履歴は、事前に交通手段を調べるユーザが多いことから、将来の人混み具合の指標として利用されてきた [3], [4], [11]。一方、乗換検索履歴からは、ユーザが目的地に設定する鉄道駅周辺の混雑しかわからない。そのため、最寄駅の混雑はわかっても、会場周辺がどれくらいの人で混むのかはわからないという課題がある。

そこで本研究では、イベント会場周辺の早期群衆混雑予報に取り組む。イベント会場周辺の人混みを予報する手段

としては、会場における過去の群衆動態に対し、平均値といった統計量を算出する手法 [13], [17] や、イベントの有無や開催時刻など、外的な要因に基づいた回帰問題を解く手法 (線形回帰, 双線形回帰 [15], 多層ニューラルネットワーク) が考えられる。

しかしながらこれらの手法は、開催されるイベントの内容を考慮しておらず、イベントごとの人出の違いを捉えることができない。例えば図 1, 2 に示すように、横浜赤レンガ倉庫 (神奈川県横浜市) という同一のイベント会場においても、特定の野球球団のファン向けに開催されたイベント図 1 と、一般大衆向けに開催されたイベント図 2 では、当日の混雑の度合いは異なる。また、イベント当日の会場への出入りが自由である (制限されている) ことや、入場料の有無など、イベントの内容に含まれる様々な要因で人出は変わると考えられる。

そこで本研究では、前述のようなイベントの内容による人出の違いを捉えるために、イベントの告知情報に着目する。多くの公共イベントでは、開催に先立ってウェブ上に、イベントの開催をアナウンスする事前告知文が公開される。こういった事前告知文は、イベント名、内容、会期、会場、入場料など、人々のイベントへの参加の意思決定に影響し得る情報が含まれている。またこういったイベント告知文は、イベント主催者や会場のウェブサイトで事前に一般に公開されるため、混雑の早期予測に利用しやすい。

告知情報の特徴量として利用するために、我々はテキスト形式の告知文データを、テキスト埋め込みベクトルに変換する。その手段として、我々は近年発展著しい大規模言

¹ 東京工業大学 情報理工学系 情報工学系 Department of Computer Science, School of Computing, Tokyo Institute of Technology

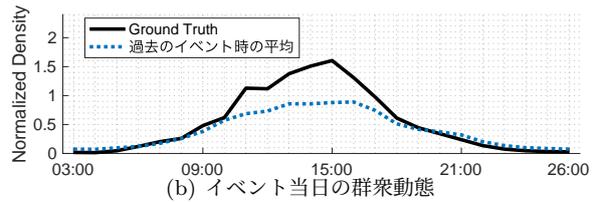
² LINE ヤフー株式会社 LY Corporation

横浜オクトーバーフェスト2019

横浜赤レンガ倉庫は、秋の風物詩「横浜オクトーバーフェスト2019」を10月4日（金）より開催します。…今年も、ドイツで最も美しいエルベ渓谷に醸造所がある「フェルトシュレーヒェン」や今年設立100年を迎える「エゲレア」など、日本初上陸のビールや同イベント限定のビア等、100種類以上のビールを用意。…

(a) イベントの事前告知情報

図 1 横浜オクトーバーフェスト 2019（横浜赤レンガ倉庫，2019 年 10 月 20 日（日））におけるイベントの事前告知情報と混雑例。

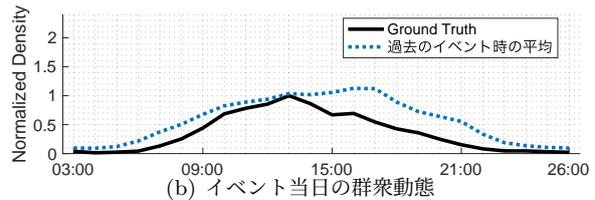


横浜DeNAベイスターズ、ランニングイベント「YOKOHAMA STAR☆NIGHT RUN 2019」

横浜DeNAベイスターズは、横浜の待ちを舞台にしたランニングエンターテインメント「YOKOHAMA STAR☆NIGHT RUN 2019」を7月6日（土）と7日（日）に開催します。横浜赤レンガ倉庫をメイン会場に、光と音の演出とともに、横浜の夜景を楽しみながら駆け抜けるナイトランイベントです。…

(a) イベントの事前告知情報

図 2 横浜 DeNA ベイスターズ・ランニングイベント（横浜赤レンガ倉庫，2019 年 7 月 7 日（日））におけるイベントの事前告知情報と混雑例。



語モデル (Large Language Models; LLM) の一つである GPT-4 [1] を活用する。GPT-4 により整形・特徴量化された告知情報に基づき、多層ニューラルネットワークを用いて、イベント当日の群衆動態を予測する。東京大都市圏に存在する、スタジアムや展示場、公園、神社仏閣、その他イベントの開催記録のある観光地等、24 の会場において、2019 ~ 2020 年に開催された合計 305 のイベントにおける性能評価実験を行い、過去のイベント下の群衆動態の平均値に基づく予測と比較して、群衆動態の予測性能が向上することを示す。また提案手法では、同一会場におけるイベントごとの人出の違いを捉えることができるようになることを示す。

本研究の貢献は以下である。

- イベントの内容を考慮して来訪者数を精緻に予報するために、イベントの告知情報に着目する。
- 大規模言語モデル (LLM) を用いて、テキスト形式で与えられる告知を整形・特徴量化し、イベント下の群衆動態のモデリングに使用することを提案する。
- 実際の人流ログデータ、イベントの告知情報を用いて、東京周辺の 24 会場 305 のイベントに対して性能評価実験を行う。実験により、提案手法においてイベントごとに異なる混雑動態を捉えることができることを示す。

関連研究

人流モデリング. GPS 位置履歴を搭載したモバイルデバイスの普及により、人流のモデリングが近年盛んに行われている。未来の人流予測に焦点を当てた代表的な手法と

して、人流の自己相関を利用したモデリング [9], [10] と、外的な要因を説明変数としたモデリング [7], [14], [15], [16] が存在する。前者は、混雑を含め精緻な予報が可能であるが、人流が自己相関を持つ数時間先の予測に限定される。後者は、人流の自己相関の代わりに外的な要因を説明変数とすることで、より間遠の未来も予報可能となる。本研究では、イベント情報といった外的な要因を説明変数として、混雑の早期の予報を可能とするモデリングを行う。

イベント下における人流モデリング. イベント下の人流に焦点を当てた研究は、そのイベントの発生が事前にわかるもの (スポーツの試合や花火大会など、主催者が開催を事前公示するもの) [2], [3], [4], [11] と、事前にわからないもの (災害など) [8], [10], [18], [21] とに分類され、本研究は前者に分類される。未来に起こるイベント下の混雑のモデル化は従来、乗換検索アプリの検索履歴をユーザの訪問予定として用いる予報手法が存在した [2], [3], [11]。一方、乗換検索に反映されるのは、ユーザの鉄道駅への訪問予定であり、イベント会場やその周辺への訪問予定まではわからなかった。そのため、既存の枠組みでは、人混みが予報可能なエリアは駅周辺に限定的であり、イベント会場周辺の混雑を早期予報することはできなかった。

2. 問題設定と変数定義

l を混雑予報を行うイベント会場周辺の対象地域、 d を日付を表す変数とし、一日の時間帯を $1, 2, \dots, T$ なる T 個のセグメントに分割し、各時間帯を t で表す。日付 d 、および時間帯 t において、地域 l において観測される携帯端末

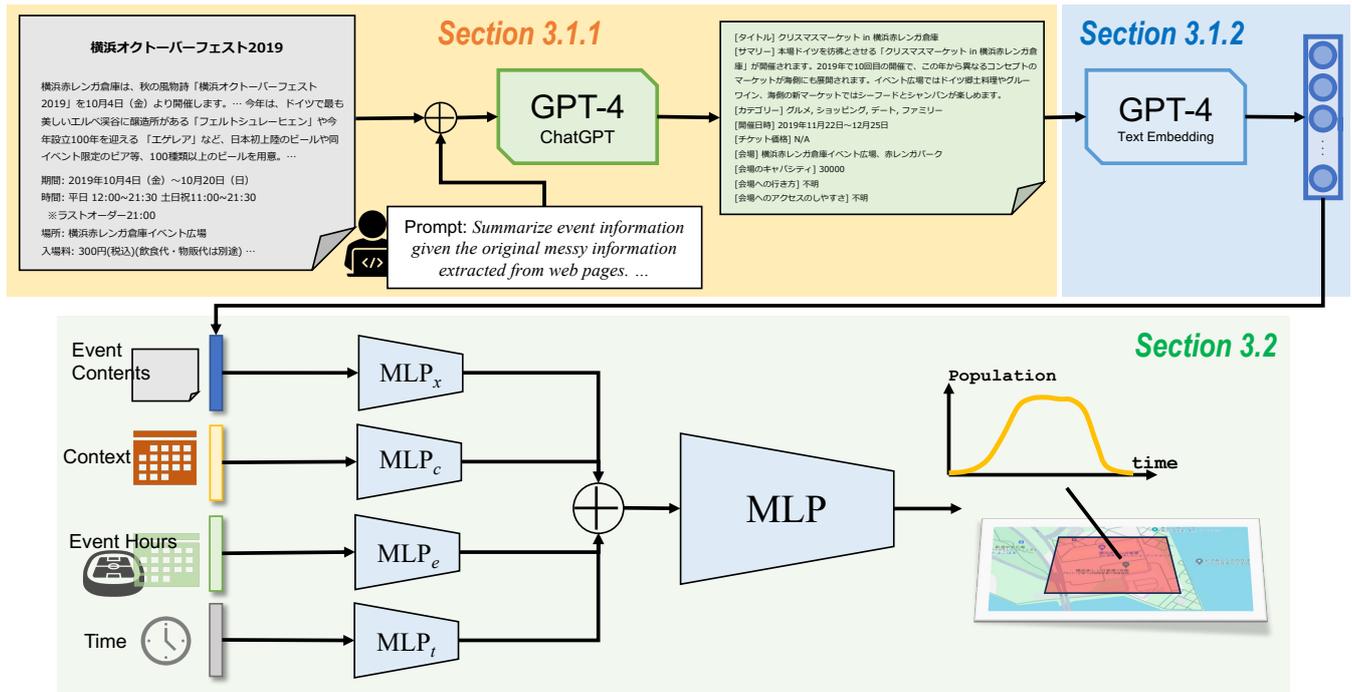


図 3 提案手法の概略図。

位置履歴のカウント数を群衆密度と定義し、 $y_{l,d,t}$ で表す。

また、イベントを $e_{l,d}$ とし、主催者によって事前に公示されるイベント内容に関する埋め込みベクトルを $x_{l,d} \in \mathbb{R}^X$ 、開催時刻に関する特徴量を $e_{l,d}$ とする。最後に、時間ステップ τ における時刻 t の特徴量を $t \in \mathbb{R}^T$ 、日付 d における平休日や曜日といったコンテキストによる特徴量を $c_d \in \mathbb{R}^C$ とする。

本研究では、イベント内容の埋め込み $x_{l,d}$ 、イベントの開催時刻特徴量 $e_{l,d}$ 、時刻特徴量 t 、コンテキスト特徴量 c_d に基づいて、群衆密度 $y_{l,d,t}$ を予測する問題に取り組む。

3. 提案手法

本研究では、過去のイベント下の群衆動態に基づく予測手法の課題の解決に取り組む。その課題とは、公共イベントの内容を考慮していないことにより、イベントごとの人出の違いを捉えることができなかったことである。

この課題への対処のため、イベント主催者や会場の Web ページで事前に公開される、イベントの開催告知情報に着目する。告知情報は図 1, 2 に示すように、イベント名、内容、会期、会場、入場料など、人々のイベントへの参加の意思決定に影響し得る情報が含まれている。一方、こういったイベント告知情報はテキストデータであり、そのフォーマットはイベント間で統一されていないため、そのままではモデルの入力として利用できない。

そこで本研究ではまず、イベント告知情報を元の生テキストから、内容や開催日時などの重要な情報を抽出し、統一したフォーマットに整形する (3.1.1 章)。整形されたイベント情報は、固定長の埋め込みベクトル $x_{l,d}$ に変換さ

Summarize event information given the original messy information extracted from web pages.

Requirements:

- The output MUST BE in JAPANESE.
- INCLUDE ONLY information RELEVANT to event popularity.
- ALWAYS MAKE SURE to output only the facts.
- DO NOT include the information that cannot be known before the event is held (e.g., the scores of games).
- Use the present tense.
- Be clear, complete, and concise WITHIN 100 words.
- Identify specific event category if you are confident (e.g., Rock Concert, Comedy Show).
- Extract the accessibility of the event venue (e.g., how many minutes it takes from the nearest station).
- Use your existing knowledge to enhance details about the event and performers when original information is limited.
- Extract hour and date information about event, if no time is mentioned, assume full days.
- Strictly follow the following output format.

Output Format:

[タイトル] {String. Title of the event.}

[サマリー] {String. Summarized description of the event, which MUST be in Japanese}

[カテゴリ] {String. List up the event categories that are specified in the original information or identified by you.}

[開催日時] {String. List up the event date and hours that are specified in the original information.}

[チケット価格] {Integer. If the original information includes the ticket prices, please fill in this item. If not, please fill this with N/A.}

[会場] {String. Venue of the event.}

[会場のキャパシティ] {Integer. If the original information include the capacity of the venue, please fill in this item. If not, please fill this with N/A. NUMBER ONLY, NO TEXT.}

[会場への行き方] {String. Describe how to get the event venue. If not mentioned by the original information, write 不明.}

[会場へのアクセスのしやすさ] {String. Describe the accessibility to the event venue. Output only the facts. If not mentioned by the original information, write 不明.}

図 4 整形に使用したプロンプト。

れる (3.1.2 章)。最後に、埋め込みベクトル $x_{l,d}$ 及び 2 章で導入した入力特徴量をもとに、群衆密度をモデル化する (3.2 章)。これらの実現には、近年発展著しい LLM を用いる。図 2 には、本研究における提案手法の概略図を示す。

3.1 LLM によるイベント告知情報の整形・特徴量化

3.1.1 イベント告知情報の整形

先に述べたように、イベント告知情報はテキスト形式であり、統一フォーマットは有していない。したがって本研究では、テキスト形式で与えられるイベント情報から、イベントタイトル、内容のサマリー、イベントの開催日時、チケット価格などを自動で抽出し、テキストデータを整形

する。

データ整形のために、本研究では大規模言語モデルの一つである GPT-4 [1] の、チャット補完タスクを利用する。チャット補完 (Chat Completion) タスクはテキスト生成タスクの一種であり、ChatGPT*1 に代表されるように、「プロンプト」と呼ばれるユーザが与えるテキスト形式の指示・投げかけ、言語モデルが応答文テキストを生成することで、チャットの内容を補完するタスクである。GPT-4 (ChatGPT) は、チャット補完タスクにおいて有望な性能を達成している。

図 3.1.1 には、今回の告知情報の整形に使用したプロンプトを示す。プロンプトはまず、”Summarize event information given the original messy information extracted from web page.” と前置きし、指示の内容を簡潔に伝えた。さらに、データを統一化・構造化するため、出力のフォーマットを指定した。図 2 上部には、イベント「横浜オクトーバーフェスト 2019」の事前告知文に対し、ChatGPT によって整形を行なった結果を示す。

3.1.2 イベント告知情報の特徴量化

本研究では、整形したイベントの告知情報を、LLM のテキスト埋め込みタスクを用いて、固定長のベクトル $\mathbf{x}_{l,d}$ として特徴量化する。今回我々は、GPT-4 モデルの「テキスト埋め込み生成タスク」を利用し、テキストデータを埋め込みベクトルに変換した。この場合、 $\mathbf{x}_{l,d} \in \mathbb{R}^{1536}$ となる。ただし、この埋め込みモデルは、他の言語モデル、例えば Doc2Vec [12] や事前学習済み BERT [20] といった、様々なテキスト埋め込みの変換・生成技術に置き換え可能である。

3.2 イベント内容埋め込みを用いた群衆動態モデリング

前節までで求められた $\mathbf{x}_{l,d}$ 、また 2 章で定義した入力特徴量を元に、群衆密度 $y_{l,d,t}$ をモデル化する。先行研究 [15] と同様に本研究でも、群衆密度がポアソン分布 Poisson に従い、 $\mathcal{P}(y_{l,d,t}) = \text{Pois}(y_{l,d,t} | \lambda_{l,d,t}^{(l)})$ となると仮定する。ここで $\lambda_{l,d,t} > 0$ はポアソン分布の平均パラメータである。本手法では、この平均パラメータ $\lambda_{l,d,t}$ を、入力特徴量 $\mathbf{x}_{l,d}$ 、 $\mathbf{e}_{l,d}$ 、 \mathbf{t} 、 \mathbf{c}_d に基づいてモデル化する。そのために我々は、図 2 下部に示すような、多層ニューラルネットワークモデルを用いる。本モデルではまず、入力特徴量を多層パーセプトロン (Multi Layer Perceptron; MLP) を用いて、埋め込みに変換する。

$$\mathbf{h}_{\mathbf{x}_{l,d}} = \text{MLP}_x(\mathbf{x}_{l,d}) \quad (1)$$

$$\mathbf{h}_{\mathbf{e}_{l,d}} = \text{MLP}_e(\mathbf{e}_{l,d}) \quad (2)$$

$$\mathbf{h}_{\mathbf{t}} = \text{MLP}_t(\mathbf{t}) \quad (3)$$

$$\mathbf{h}_{\mathbf{c}_d} = \text{MLP}_c(\mathbf{c}_d) \quad (4)$$

$\mathbf{h}_{\mathbf{x}_{l,d}}$ 、 $\mathbf{h}_{\mathbf{e}_{l,d}}$ 、 $\mathbf{h}_{\mathbf{t}}$ 、 $\mathbf{h}_{\mathbf{c}_d} \in \mathbb{R}^H$ はそれぞれ、イベントの内容、イベントの開催時刻情報、予測対象の時刻、コンテキスト情報に関する学習可能な埋め込みベクトルである。さらに、これらの埋め込みベクトルの重み付き和を取り、一つの隠れ特徴量に集約する。

$$\begin{aligned} \mathbf{h}_{l,d,t} = & \mathbf{w}_{\mathbf{x}_{l,d}} \odot \mathbf{h}_{\mathbf{x}_{l,d}} + \mathbf{w}_{\mathbf{e}_{l,d}} \odot \mathbf{h}_{\mathbf{e}_{l,d}} \\ & + \mathbf{w}_{\mathbf{t}} \odot \mathbf{h}_{\mathbf{t}} + \mathbf{w}_{\mathbf{c}_d} \odot \mathbf{h}_{\mathbf{c}_d} \end{aligned} \quad (5)$$

ここで $\mathbf{w}_{\mathbf{x}_{l,d}}$ 、 $\mathbf{w}_{\mathbf{e}_{l,d}}$ 、 $\mathbf{w}_{\mathbf{t}}$ 、 $\mathbf{w}_{\mathbf{c}_d} \in \mathbb{R}^H$ は学習可能なパラメータであり、また \odot はベクトル同士の要素積である。ここで求められた $\mathbf{h}_{l,d,t}$ を用いて、ポアソン分布のパラメータ $\lambda_{l,d,t}$ を以下のように定式化する。

$$\ln \lambda_{l,d,t} = \text{MLP}(\mathbf{h}_{l,d,t}) \quad (6)$$

ここで、MLP の出力を $\lambda_{l,d,t}$ の対数とすることで、 $\lambda_{l,d,t} > 0$ であることを保証する。本モデルは、ポアソン分布の負の対数尤度の最小化を用いて学習する。

4. 性能評価実験

イベント会場周辺の早期群衆混雑予報における、提案手法の性能を評価するため、実イベントデータを用いた性能評価実験を行った。

4.1 実験設定

モデルに与えるコンテキスト情報として、曜日情報、平休日情報、祝日情報を用いた。曜日情報を $\mathbf{c}_d^{(1)} \in \mathbb{R}^7$ 、平休日情報を $\mathbf{c}_d^{(2)} \in \mathbb{R}^2$ 、祝日情報を $\mathbf{c}_d^{(3)} \in \mathbb{R}^2$ とした時、コンテキスト特徴量を $\mathbf{c}_d = \mathbf{c}_d^{(1)} \otimes \mathbf{c}_d^{(2)} \otimes \mathbf{c}_d^{(3)} \in \mathbb{R}^{28}$ として与える。時間特徴量は、先行研究 [15] に従い、 $\mathcal{N}(\cdot | \tau, \sigma^2)$ を、平均パラメータ τ 、分散パラメータ σ^2 により規定される正規分布とし、時間特徴量を $\mathbf{t} = \{t_j | t_j = \mathcal{N}(j | \tau, \sigma^2), j = 1, \dots, T\}$ と与える。

また、予測モデルの学習には、早期終了を用いた。この時、テストデータ以外のデータを 9 対 1 に分割し、前者を学習データ、後者を評価データとし、評価データに対する損失値が 10 エポック間改善されなくなるまで学習データに対しモデルのパラメータ更新を行う。その後、学習データと評価データを双方用いて、10 エポックの固定回学習を行い、モデルの収束とする。性能評価指標には、実際の群衆密度の大きさごとの、群衆密度の絶対予測誤差 (Mean Absolute Error; MAE) を用いる。

本実験では提案手法を、学習データにおけるイベントが発生した日における群衆密度推移の平均値で予報を行う **Event-aware Historical Average (EHA)** と比較した。データの処理・解析には、Apach Spark [23] の MapReduce

*1 <https://chat.openai.com/>

フレームワークを用いた。また、提案手法における深層学習モデルの実装には、Apache Spark 上で動作をする分散型深層学習フレームワークである、BigDL 1.0 [5] を用いた。

4.2 実験データ

本実験では、実際の GPS 位置履歴データを使用した、早期群衆混雑予測の性能評価を行った。

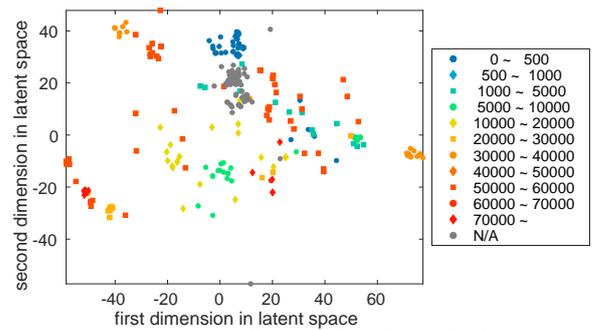
本実験で用いる GPS 位置履歴は、LINE ヤフー株式会社から提供されているモバイルアプリケーションによってユーザーの同意のもとで取得された位置履歴情報である。データはタイムスタンプと緯度経度の情報を持ち、日本全国のユーザーから取得されている。データ数は東京圏のみで 1 日に約 1500 万件にも及ぶ。データは事前にユーザー情報を取り除くことで匿名化し、さらに解析対象地域におけるログ数を 60 分間隔でカウントし、統計情報化したものである。そのため、最終的なデータは、日付、時刻、ログのカウント数からなるデータであり、個人を特定できるものではない。解析対象地域は、表 1 に示す会場をはじめとした、東京大都市圏に存在する、スタジアムや展示場、公園、神社仏閣、その他イベントの開催記録のある観光地等の 24 会場周辺の、500 × 500 m 四方の正方形エリアとした。また利用するデータの期間は、2019 年 2 月 1 日から 2020 年 1 月 31 日までの 1 年間とした。

また、実験に用いるイベントの告知情報を、表 1 に示す会場のウェブサイトや、イベント主催者のホームページから収集した。その結果、前述のデータ収集期間において、24 会場から合計 305 のイベントデータを収集した。データセットにはイベントに関する説明文が含まれ、その文章の中には、イベント名、内容に関する説明文、開催時刻情報、イベントの категория、イベント会場の収容人数などが含まれる。今回の実験では、全情報をイベント内容の埋め込みベクトル化に使用し、また各日付における開催時刻、終了時刻をイベント開催時刻特徴量として利用した。

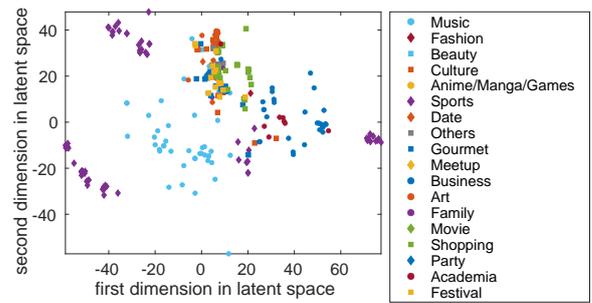
4.3 イベント埋め込み特徴量の可視化

本節ではまず、3.1 章にて作成したイベントの内容に関する埋め込み特徴量を可視化し、イベントの内容を適切に反映した特徴量と言えるかを定性的に確認する。そのため我々は、解析対象である 305 個のイベントに対して、内容の埋め込み $x_{i,d}$ を T-SNE 法 [19] を用いて次元圧縮を行い、2 次元空間上に散布図として可視化した。

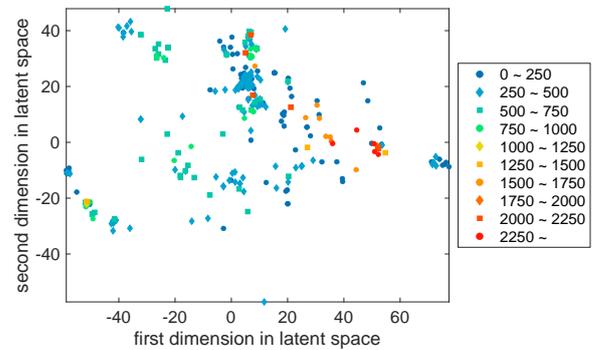
図 5 には、埋め込み $x_{i,d}$ の圧縮結果の散布図を示す。図 5(a)、5(b) はそれぞれ、イベント会場の収容人数規模、イベントの各カテゴリーごとに色付けを行なった散布図である。この結果から、同じ会場収容人数規模、イベントの category を持つイベントは、埋め込みが近い位置に射映されており、今回作成した内容の埋め込みは、イベントの内容を反映した埋め込みベクトルであることがわかる。



(a) イベント会場の収容人数ごとの可視化。



(b) イベントカテゴリーごとの可視化。



(c) 各イベント開催時の会場周辺での実際の群衆密度規模ごとの可視化。

図 5 イベント内容埋め込み特徴量の T-SNE による可視化。

また、図 5 は、内容の埋め込みを、各イベント開催時の会場周辺での実際の群衆密度規模別に可視化したものである。ここで群衆密度規模の情報は、埋め込み作成時の入力としては用いていないことに注意されたい。この結果より、近い群衆密度規模であったイベントは、ある程度のまとまりを持って分布していることがわかる。以上から、イベント内容埋め込み $x_{i,d}$ が、イベント時の混雑動態を予測する際に用いる情報として有効であることが伺える。

4.4 実イベントデータを用いた性能評価実験

表 2 には、イベント内容埋め込みを用いた学習法である MLP+LLM と、比較手法である EHA での、イベント時の群衆密度の予測性能を比較した結果を示す。All の結果に示されるように、概してイベント内容を考慮した MLP+LLM が EHA の予測性能を上回った。また規模別に見ても、群衆密度が 0 ~ 1500 の範囲では、MLP+LLM が EHA の性能を上回った。このことから、イベント内容の考慮はイベント会場周辺の混雑予測に対して効果が認め

表 1 実データにおける解析対象イベント会場の例.

会場の種類の例	会場例
スタジアム	日産スタジアム (神奈川県横浜市), 味の素スタジアム (東京都調布市), 東京ドーム (東京都文京区), etc.
展示場・ホール	東京ビッグサイト (東京都江東区), 東京国際フォーラム (東京都千代田区), パシフィコ横浜 (神奈川県横浜市), etc.
神社・仏閣	浅草神社 (東京都台東区), 大本山 増上寺 (東京都港区).
公園	日比谷公園 (東京都千代田区), 代々木公園 (東京都渋谷区), 山下公園 (神奈川県横浜市), etc.
観光地	横浜赤レンガ倉庫 (神奈川県横浜市), 新宿御苑 (東京都新宿区・渋谷区) etc.
河川敷	隅田川 (隅田川花火大会会場周辺, 東京都墨田区), 多摩川 (世田谷区たまがわ花火大会会場周辺, 東京都世田谷区).

表 2 実イベントデータにおける予報性能の評価. All は, データ全体での評価を表し, それ以外は実際の群衆密度を 500 人単位で分割し評価した結果である.

Model	All	0 ~ 500	500 ~ 1000	1000 ~ 1500	1500 ~ 2000	2000 ~ 2500	2500 ~ 3000	3000 ~
EHA	115.48	69.43	263.06	530.13	562.27	958.84	1385.00	2071.91
MLP+LLM	101.86	51.04	250.35	521.78	812.16	1104.46	1305.40	2225.65

られたと言える.

一方, 群衆規模が大きい範囲のイベント (例えば 1500 を超えるもの) では, MLP+LLM により EHA の予報性能を上回ることができなかった. これは, 規模の大きいイベントでは開催される会場が限定的であり, 同会場で開催されるイベント下の来訪者数のばらつきが少なかったためと考えられる. また MLP+LLM は, 予報対象の会場のデータに加えて, 他会場のデータも学習データとして用いている. そのため, 訪問者数規模の異なる他会場の学習データがノイズとなり, このような予報性能の劣化を引き起こしている可能性がある. モデルの入力特徴量に, 会場の特性を表す特徴量を含めることで, この課題を解決できる可能性がある. 近年, 会場や POI の特性を特徴量化する手法 (例えば Place2Vec [22]) も盛んに研究されており, そのような技術を組み込むことで, 予報性能の安定化が見込める.

4.5 群衆混雑予報の可視化

本節では, 同一会場における異なるイベント下の混雑予報の可視化を示すことで, 提案手法 MLP+LLM が, イベント内容による訪問者数の一概を捕捉可能であることを示す.

図 6 には, 同一会場 (横浜赤レンガ倉庫) における, 異なる 3 つのイベント (イベント 1: 横浜オクトーバーフェスト 2019, イベント 2: 横浜 DeNA ベイスターズ・ランニングイベント, イベント 3: クリスマスマーケット in 横浜赤レンガ倉庫) の予測結果の可視化を示す. 上段図 6(a) ~ 6(c) は, 会場のウェブサイトで事前に公開されたイベントの告知情報, 中段図 6(d) ~ 6(f) は告知情報の LLM による整形結果, 下段図 6(g) ~ 6(i) は, EHA 及び MLP+LLM による当日の混雑予報予測結果である. ここで, 下段の予測結果は, イベント 2 の群衆密度推移を基準に正規化を行っている. すなわち, イベント 2 の群衆密度が 1, イベント 1 の群衆密度が 2 である場合, イベント 1 はイベント 2 より 2 倍の人出があったことを表す.

図 6(d) ~ 6(f) からわかるように, 3 つのイベントは内容の異なる催し物である. またイベント 1 の入場料は 300 円と比較的安価であるのに対して, イベント 2 の入場料は大人一名 6500 円と高価に設定されている. このような違いにより, 図 6(g) ~ 6(i) 内の黒線で示されるように, 当日の会場の群衆密度は, イベント 2, 3 と比べて, イベント 1 では約 2 倍の人出を記録している.

これに対し, 提案手法 LLM+MLP の予測結果は, EHA の予測結果と比較して, 各イベントでの群衆密度規模を正確に捉えている. なお, イベント内容テキストを特徴量ベクトルに埋め込む際, 会場の収容人数情報は用いたが, 当日の来場者数の見込みなどの情報は用いていないことに注意されたい. それにも関わらず, LLM+MLP による当該予測結果は, 同一の収容人数を有する会場において, イベント間の訪問者数スケールの違いが予測可能であることを示している. このことから, 提案手法はイベントの内容を考慮することで, イベントによる人出の違いを捉えることが可能になったと言える.

5. 結論

本研究では, イベントの内容を考慮したイベント会場周辺の早期群衆混雑予報に取り組んだ. イベントの内容を考慮するために, イベントの事前告知情報に着目し, 大規模言語モデル (LLM) を用いて告知情報を整形・特徴量化することを提案した. 実験結果より, イベント内容を考慮することで, 過去のイベント化の平均値による予測と比較して, 群衆密度の予報性能を MAE で 13.4%改善できることを示した. また, イベントの内容を考慮することで, 同一のイベント会場における異なるイベント間の人出の違いを捉えることが可能になった. 一方, 提案手法では人出の多い場合における群衆密度の予報性能が, EHA に劣ることがわかった. 将来課題としては, この課題の解決のために, イベントの内容に加えてイベント会場の場所特性を考慮することが考えられる.

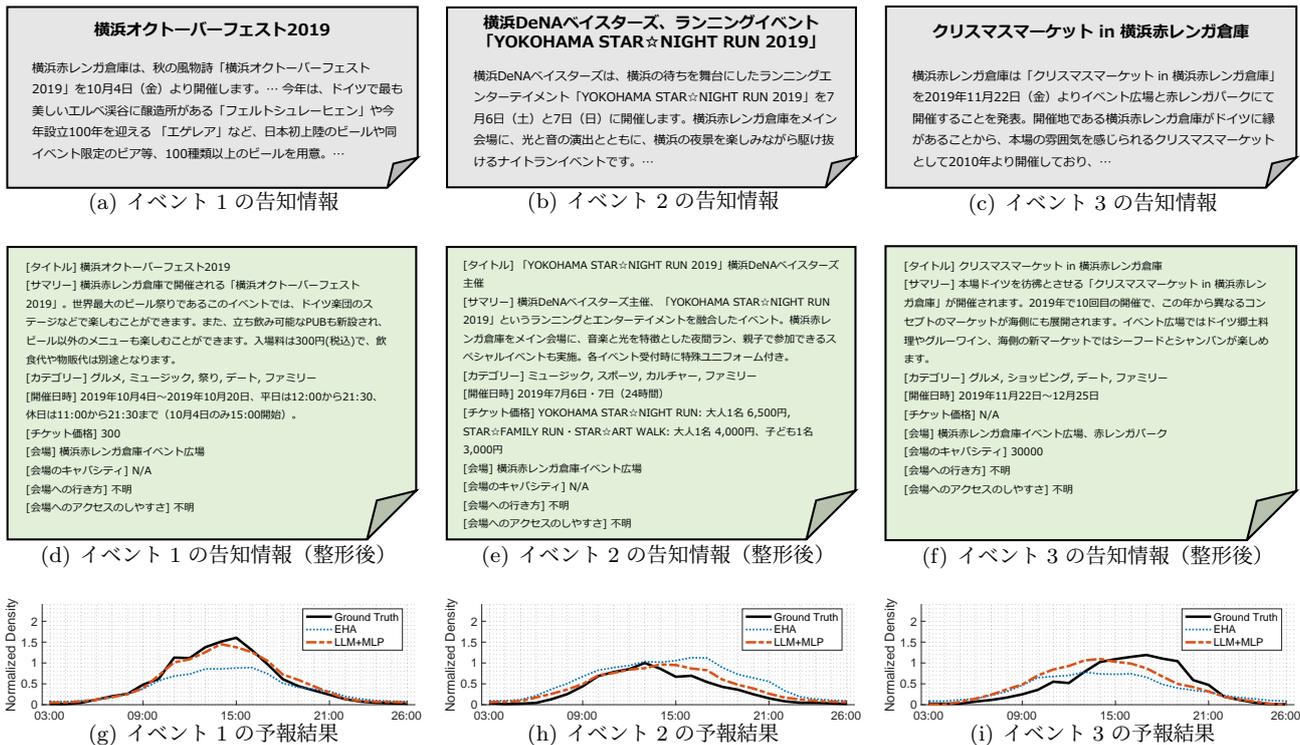


図 6 同一会場における異なるイベントの予測結果の可視化.

参考文献

[1] J. Achiam et al. GPT-4 technical report. *arXiv preprint arXiv:2303.08774*, 2023.

[2] S. Anno et al. Supervised-cityprophet: Towards accurate anomalous crowd prediction. In *Proc. of SIGSPATIAL*, 2020.

[3] S. Anno et al. CityOutlook: Early crowd dynamics forecast towards irregular events detection with synthetically unbiased regression. In *Proc. of SIGSPATIAL*, 2021.

[4] S. Anno et al. CityOutlook+: Early crowd dynamics forecast through unbiased regression with importance-based synthetic oversampling. *IEEE Pervasive Computing*, 2023.

[5] J. J. Dai et al. Bigdl: A distributed deep learning framework for big data. In *Proc. of the ACM Symposium on Cloud Computing*, 2019.

[6] Z. Fan et al. Citymomentum: An online approach for crowd behavior prediction at a citywide level. In *Proc. of UbiComp*, 2015.

[7] Y. Hayakawa et al. Simultaneous multiple poi population pattern analysis system with hdp mixture regression. In *Proc. of PAKDD*, 2021.

[8] R. Jiang et al. Deepurbanevent: A system for predicting citywide crowd dynamics at big events. In *Proc. of SIGKDD*, 2019.

[9] R. Jiang et al. Dl-traffic: Survey and benchmark of deep learning models for urban traffic prediction. In *Proc. of CIKM*, 2021.

[10] R. Jiang et al. Learning social meta-knowledge for now-casting human mobility in disaster. In *Proc. of TheWebConf*, 2023.

[11] T. Konishi et al. Cityprophet: City-scale irregularity prediction using transit app logs. In *Proc. of UbiComp*, 2016.

[12] Q. Le and T. Mikolov. Distributed representations of sentences and documents. In *Proc. of ICML*, 2014.

[13] M. Moussaïd et al. How simple rules determine pedestrian behavior and crowd disasters. *PNAS*, 108(17):6884–6888, 2011.

[14] M. Okawa et al. Online traffic flow prediction using convolved bilinear poisson regression. In *Proc. of MDM*, 2017.

[15] M. Shimosaka et al. Forecasting urban dynamics with mobility logs by bilinear poisson regression. In *Proc. of UbiComp*, 2015.

[16] M. Shimosaka et al. Spatiality preservable factored poisson regression for large-scale fine-grained gps-based population analysis. In *Proc. of AAAI*, 2019.

[17] B. L. Smith et al. Traffic flow forecasting: comparison of modeling approaches. *Journal of transportation engineering*, 123(4):261–266, 1997.

[18] A. Sudo et al. Particle filter for real-time human mobility prediction following unprecedented disaster. In *Proc. of SIGSPATIAL*, 2016.

[19] L. Van der Maaten and G. Hinton. Visualizing data using t-sne. *Journal of machine learning research*, 9(11), 2008.

[20] T. Wolf et al. Huggingface’s transformers: State-of-the-art natural language processing. *arXiv preprint arXiv:1910.03771*, 2019.

[21] T. Yabe et al. A framework for evacuation hotspot detection after large scale disasters using location data from smartphones: Case study of kumamoto earthquake. In *Proc. of SIGSPACIAL*, 2016.

[22] B. Yan et al. From itdl to place2vec: Reasoning about place type similarity and relatedness by learning embeddings from augmented spatial contexts. In *Proc. of SIGSPATIAL*, 2017.

[23] M. Zaharia et al. Spark: Cluster computing with working sets. *HotCloud*, 2010.