

# 施設管理支援に向けた常時型人流予測

角田 啓介<sup>1,a)</sup> 秦 崇洋<sup>1,a)</sup> 尾花 和昭<sup>2,a)</sup>

受付日 2021年2月8日, 採録日 2021年10月8日

**概要:** 本稿では, 商業ビルをはじめとする施設における, 空調制御や清掃, テナントへの支援といった管理業務の支援を目指し, 施設内における人の方向別の移動人数や速度といった人流を数日前に予測する手法を提案する. 従来の人流予測技術では主に, 混雑緩和や誘導の向けた数分から数時間後の人流, または数時間から数日後の特定エリアの滞在人数のみを予測していた. しかしながら, 実際の設備管理において, 管理業務に必要な物品や人材, 装置などを事前準備するために, 日常において曜日や時間帯によって変化する多様な人流データを, 1日以上前に予測することが必要である. 本稿では, 過去の人流計測データとそれらが持つ平日・休日といった特徴に基づき, 1日以上前に未来日における各時刻の人流を予測する常時型人流予測手法を提案する. そして, 提案手法を実際の施設で計測した人流データに適用することで, その有効性を示す.

キーワード: 人流, 施設管理, 長期予測

## Continuous Prediction of People Flow for Supporting Facility Management

KEISUKE TSUNODA<sup>1,a)</sup> TAKAHIRO HATA<sup>1,a)</sup> KAZUAKI OBANA<sup>2,a)</sup>

Received: February 8, 2021, Accepted: October 8, 2021

**Abstract:** This paper proposes prediction method of people flow at several days later in a facility such as shopping mall for supporting facility management including air-conditioning, cleaning, maintenance and support for tenant shops or restaurants. Existing studies have tackled to predict people flow at several minutes or hours later, or only number of occupancy at several hours or days later. However, it is important and necessary for facility manager to understand people flow including number of visitors, direction of them and average of these speed until several days ago because they must plan air-conditioning control, cleaning and maintenance with preparation of workers and so on. To support their daily facility management, we propose a novel method to predict number of moving people and average of their speed in each defined direction in such facility at tomorrow or later based on characteristics of past people in holiday and weekday. We evaluated effectiveness of our proposal using measured data in the shopping mall.

**Keywords:** people flow, facility management, long term prediction

### 1. 緒言

近年, 商業ビル, 駅, 地下街といった様々な人々が集う施設は, 人々にとっての目的を達成する場であるだけでな

く, 様々な人やモノが集い, 出会う機会を提供する重要なインフラストラクチャとなりつつある. そのような施設の管理者にとっては, 稼働率や集客率の向上と同時に, 入居テナントや来場者にとって価値があり, かつ居心地の良い空間になるような管理・運営が非常に重要である. しかしながら同時に近年, 日本では少子高齢化や労働力の減少が顕著であり, このような施設の管理・運営業務には, 特に ICT 技術の活用によるいっそうの効率化が求められている [1].

<sup>1</sup> 日本電信電話株式会社 NTT スマートデータサイエンスセンター  
NTT Smart Data Science Center, Minato, Tokyo 108-0023, Japan

<sup>2</sup> 日本電信電話株式会社 NTT 未来ねっと研究所  
NTT Network Innovation Laboratories, Yokosuka, Kanagawa 239-0847, Japan

<sup>a)</sup> cdep-cm-submission@hco.ntt.co.jp

本稿では、そのような施設の管理・運営を支援するための取り組みとして、日々、その施設の中で起こる人の流れである「人流」のうち、方向別通過人数やその平均速度に着目し、それらの人流を日常業務で利用できるよう予測する手法について述べる。従来の人流予測技術では、イベント開催時や災害時などにおける混雑情報となる数分から数時間後の人流や、滞在人数のみに着目した数時間から数日後の予測が試みられていた。しかしながら、施設の管理・運営は24時間365日休みなく実施される必要があり、イベント時のような短期間における画一的なパターンだけでなく、管理に必要な資材や人材を確保するためにも、日付、曜日、時間帯、場所などによって変化しうる、単なる滞在人数だけではない様々な人流パターンを、1日以上前に予測する必要がある。本稿では、施設の来場者の流れには場所や方向、予測日やその前後平日、休日によってある程度規則性があることに着目し、学習データを選択して予測モデルを作成して予測することで、精度良く人流を予測できる常時型人流予測手法を提案する。また、提案手法を商業施設における実測データへ適用し、その有効性を示す。

## 2. 関連研究

### 2.1 人流計測

本節では、主に屋内における人流計測に関する関連研究について述べる。屋内における人流計測手法としては、大きく直接的な計測手法と間接的な計測手法に分類できる。

直接的な計測手法とは、人の存在や動きをセンサ機器で直接とらえる方法を指す。代表的なものとして、カメラ画像で人の存在や動きを検知する方法 [2] や、Laser Range Finder [3] や LiDAR [4] といった光学的センサで人の動きをとらえる方法があげられる。これらの手法では、単一センサではそのセンサが計測できる限られたエリアでの人の動きのみを検知するため、設置した空間内に存在する人数を計測することができる。また、センサを複数台設置してそれらの計測データを統合することで、より広い空間内での各人の動きを計測することが可能である。さらに、多くの人が行き来する空間を対象とした人流計測では各人の動きをすべて把握するのではなく、統計値として移動する方向や速度、人の密度をカメラ画像から把握する技術も提案されている [5]。

他方、間接的な計測手法とは、人の存在や動きに関連する情報を得ることで、人の動きや存在を推定する方法を指す。代表的なものとして、人が持つスマートデバイスが発信する WiFi や Bluetooth の信号を検知するもの [6]、人の呼気に含まれる二酸化炭素 (CO<sub>2</sub>) 濃度を用いるもの [7]、人の存在による WiFi 信号の伝搬の変化をとらえるもの [8] などがあげられる。これらの手法も直接的な手法と同様、ある空間内の存在人数を計測することは可能とうえ、スマートデバイスの信号を用いる場合は、その信号から人の

動きをある程度追尾することも可能である。

以上より、屋内における人流計測には直接的手法と間接的手法があり、それぞれ長所・短所はあるものの、一般に人流計測での把握粒度として、あるエリア内に存在する人数の把握と、エリア内に存在する各人の移動軌跡まで把握の2種類があり、またエリア内における人の動きのデータからは、そのエリアにおける方向別の移動人数や、平均速度といった人流の統計値も算出可能である。よって、人流計測のレベルとしては以下3つがあるといえる。

- 個人の振舞いレベル
- 個人の振舞いの統計値レベル
- 滞在人数レベル

### 2.2 人流予測

本節では、施設内における人流データの予測に関する関連研究について述べる。

まず、各人の振舞いレベルに着目した手法として、Alahi らは群衆の動画から人を抽出し、彼らの今後数秒の動きを Recurrent Neural Network (RNN) で予測する技術を提案している [9]。また、Ziebart らは人の目的地に向けた行動をマルコフ決定過程と見なしてモデル化し、推定する技術 [10] を提案している。これらの技術はいずれも、最長でも数時点先のデータを予測する技術である。

各人の振舞いの統計値レベルに着目した手法として、Ueda らは、想定外の混雑を予測するため、イベント会場などにおいて複数地点で測定した通過人数から、各場所における潜在的な特徴をとらえたうえで、数分から数十分後の混雑する経路、すなわち地点間の総移動人数を予測する技術を提案している [11]。Ueda らの技術は自己回帰モデル [12] の拡張であり、最長で数点先の予測が可能である。

人数レベルに着目した手法として、Erickson らは空調制御最適化に向けた、室内人数変化パターンの抽出とそれに基づいた数時間窓先の滞在人数の予測手法を提案している [14]。Adamopoulou らは室内滞在人数変化のマルコフモデルと各時点のコンテキストに基づいた数時間窓先の滞在人数の予測手法を提案している [13]。

## 3. 要件と課題

### 3.1 問題設定

本節では、本稿で目指すべき人流予測の要件の明確化に向け、問題設定を述べる。まず、本稿での支援対象は前述のように、商業ビルや駅をはじめとする、不特定多数の人間が常時行きかう空間である施設の管理や運営である。ここでの管理や運営には、施設の清掃や補修、空調や照明の制御およびメンテナンス、入居するテナントに対する情報提供や運営支援が含まれる。そして、施設の管理や運営を担当する管理者は、このような管理・運営における経費削減や付加価値向上が急務である。そして、それらの施設

表 1 要件と関連研究の関係

Table 1 Relationship between our requirements and related works.

関連研究	予測対象粒度予測対象	時間窓	予測対象時点
[9]	× (個人の振舞い)	× (数秒以下)	× (数時間窓先)
[10]	× (個人の振舞い)	× (数秒から数分)	× (数時間窓先)
[11]	○ (個人の振舞いの統計値レベル)	○ (数分から数時間)	× (数時間窓先)
[14]	× (滞在人数レベル)	× (数時間以上)	○ (数十時間窓先)
[13]	× (滞在人数レベル)	× (数分)	× (数時間窓先)

における人流は、1日を通じて一定ということとはほとんど考えられず、最短で数分、多くは数十分程度でパターンが次々と変化すると想定される。

商業施設などにおける経費には光熱費といわれるエネルギーの経費があるが、商業ビルであるデパートやオフィスビルでは冷暖房によるエネルギー消費は全体の約40%にも及ぶという環境省の統計がある[15]。また、人は体温があるため室温へ影響を及ぼし、また刻々によって人の出入りとともに起こる外気の流入や流出も室温へ影響する。さらに、空間にいる人の温熱感による快適度の指標として Predicted Mean Vote (PMV) [16] があるが、PMV に寄与する指標としては人の運動量、すなわち歩く人の速度が含まれる。そのため、施設内において、空調制御の区画や出入口などに対応して定義したエリアごとに、数十分ごとにおける人の人数や、通過する方向および歩行速度を把握することは、空調の最適制御による来館者の快適性向上や光熱費削減につながり、価値があると考えられる。加えて、清掃や補修にともなう一時的な通行制限を、夜間帯でなく日中に実施することで、人的コストなどを削減することが可能と考えられるが、この場合も特定エリアにおける、数十分ごとの方向別通過人数や速度を前もって予測することは必要になると考えられる。

一方、テナントへの情報提供や運営支援は、施設の付加価値向上につながると考えられる。管理者には原則、入居テナントに対して不公平のないよう支援する必要があるうえ、各テナント内での運営は各テナントで実施することが想定されることから、管理者がハンドリングできる範囲としては施設内の通路など共用空間における人の動きとなる。また、テナントにとって事前に把握したい情報について考えると、直前では調達が難しい、仕入れや人材配置に関連する情報と考えられる。すると、それに対応する人流データとは、各テナントに隣接する共用空間における、人の量になると考えられる。さらに、人の量だけではどの程度当該テナントに関係する人間が把握が難しく、理想的には各人の属性が把握できるとよいが、プライバシーなどを考慮すると困難である。しかしながら、どのような方向や速度で何人移動しているかによって、通勤客か、買い物客かといった多数が占めるおおまかな属性は把握できる可能性があると考えられる。以上の点を考慮すると、現実的に管

理者が提供可能で、かつテナントにとって前日以前に把握する価値のある人流は、数十分ごとの共用空間を移動する人の統計値、特に方向別の移動人数や、その速度と考えられる。

### 3.2 要件

以上の問題設定より、本稿における人流予測の要件は、以下のようになる。

**予測対象粒度** 人流として、空調などに対応した各エリア内の、各時間窓における移動方向別の人数や速度が予測できること

**予測対象時間窓** 数十分の時間窓の人流を予測できること

**予測対象時点** 数十分間隔のデータで1日以上後、つまり数十時間窓先の人流が予測できること

### 3.3 課題

上記の要件と関連技術より、本稿で解くべき課題を明確化する。要件と関連研究の関係を表1に示す。表1から分かるとおり、従来技術は方向や速度を含むレベルの人流では数時間窓先の予測、数十時間窓以上先の場合は人数レベルの予測にフォーカスしており、本稿での問題設定における要件を満たさないことが分かる。

以上より本稿における課題は以下のようになる。

施設内の各エリアにおける数十分ごと方向別移動人数と速度を、予測日の1日以上前のデータのみから予測可能か否か。

## 4. 提案

### 4.1 システム全体像

本稿における提案手法を含めた全体像を図1に示す。まずシステムは大きく、既存技術である人流計測システムと、提案手法を含む人流予測システムからなる。前者の人流計測システムでは、Laser Range Finder (LRF) やカメラといったセンサを1つ以上用いて、あらかじめ定義されたエリア内での人の移動軌跡を測定し、その人のIDとともに人流軌跡DBに保存する。具体的な計測システムの例としてはLRFによる計測システム[17]があげられる。一方、

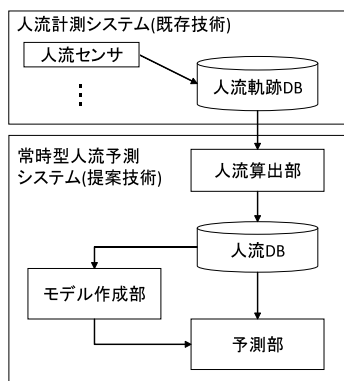


図 1 提案システムの全体像  
Fig. 1 Proposal system.

人流予測システムは、人流軌跡 DB のデータを入力として動作する。以下、基本的な動作について説明する。

本提案システムではまず最初に、既存技術である人流計測システムを用いて、対象となる施設における定義したエリアごとの人の移動軌跡を計測する。計測は複数日実施し、それらの計測結果を人流人流軌跡 DB へ保存する。

本稿で提案する人流予測システムは、上記の人流軌跡を入力とする。まず、人流算出部は人流人流軌跡 DB 内のデータを読み取ったうえで、設定されたエリアと期間ごとに、人流データを算出する。ここで述べる人流データとは要件として上述した、方向ごとの移動人数および速度である。算出結果は人流 DB へ保存される。そしてそれらのデータを基に、予測部が未来の予測対象日の人流を予測する。この際、モデル作成部が予測対象日の特徴に基づき、人流 DB から一部データを学習データとして選択し、予測モデルを作成する。予測部は作成された予測モデルに基づき、人流を予測する。次節では、学習データ選択と予測モデル作成を含む常時型人流予測手法について詳しく述べる。

#### 4.2 常時型人流予測手法

本稿では、以下の2つの考え方にに基づき、過去日のデータから1日以上先の予測日における人流を予測する手法を提案する(図2)。

- 休日・平日による人流の違いは大きいので、統一的な予測モデルを作るのではなく予測日の特徴に合わせて予測モデルを都度作成する。
- 人流は予測日自体の休日・平日に加え、その前後の休日・平日にも依存して変化しうるため、それらも考慮する。

まず前提として、予測対象とするエリア内における人流データ、具体的には任意方向への移動人数または平均速度が  $n$  日分算出され、人流 DB に保存されていると考える。つまり、第  $i$  日における時刻  $t = 1, 2, \dots, m$  の人流データを  $\mathbf{X}_i = \{X_1^i, X_2^i, \dots, X_m^i\}$  とし、第  $1 \sim n$  日までの人流データ  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$  が人流 DB に蓄積されているとする。

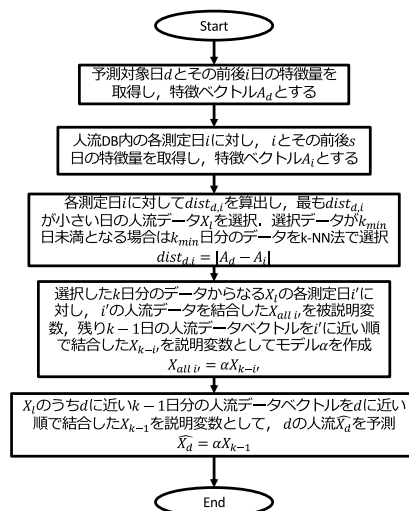


図 2 常時型人流予測の処理フロー  
Fig. 2 Flow of continuous people flow prediction.

そして、各日  $i$  は特徴量  $a_i$  を持つものとする。

予測ではまずはじめに、予測対象日  $d$  のデータに対し、その前後  $s$  日を含む特徴ベクトルを算出する。予測対象日  $d$  の特徴ベクトルは  $\mathbf{A}_d = \{a_{d-s}, a_{d-s+1}, \dots, a_d, a_{d+1}, \dots, a_{d+s}\}$  となる。次に人流 DB 内の各日データに対しても同様に特徴ベクトルを算出する。各日  $i$  の特徴ベクトルは、 $\mathbf{A}_i = \{a_{i-s}, a_{i-s+1}, \dots, a_i, a_{i+1}, \dots, a_{i+s}\}$  となる。

次に、人流 DB の各日と予測対象日の特徴ベクトルの距離を算出する。ここで、人流 DB 内の第  $i$  日のデータと予測対象日  $d$  の特徴ベクトルの距離は  $dist_{d,i}$  とする。その後、学習データとして、 $dist_{d,i}$  が最も小さい日付のデータを選択し、選択したデータ数を  $k$  とする。ここで、データの種別と  $s$  の値の大小によっては、選択されたデータ数が極端に少なくなるケースがありうる。そのため、最低学習データ日数  $k_{min}$  を定義し、 $k < k_{min}$  の場合は k-Nearest Neighbor(k-NN) 法を用いて、 $k_{min}$  件のデータを選択する。

そして、選択した学習データにおけるすべての日付  $i'$  に対し、日付  $i'$  のデータを結合したベクトル  $\mathbf{X}'_{all i'}$  を被説明変数、残りの日付のデータ  $k-1$  件を  $d$  に近い順としたものを結合したベクトル  $\mathbf{X}_{k-i'}$  を説明変数とし、以下の式でモデルとなる係数  $\alpha$  を算出する。

$$\mathbf{X}'_{all i'} \approx \alpha \mathbf{X}_{k-i'} \quad (1)$$

最後、選択したデータ  $k$  件の特徴ベクトルのうち、予測対象日に近い順に  $k-1$  日分の人流データを結合したベクトル  $\mathbf{X}_{k-1}$  とし、以下の式で予測対象日  $d$  の人流  $\hat{\mathbf{X}}_d$  を算出する。

$$\hat{\mathbf{X}}_d = \alpha \mathbf{X}_{k-1} \quad (2)$$

本手法の特徴は、学習データを選択する際、予測対象日とその前後  $s$  日の特徴量を算出し、その特徴ベクトルに基づいて予測モデルを作成したうえで予測する点である。こ

こでの特徴量とは、予測対象日が来る前その前後  $s$  日も含めあらかじめ明確である必要があり、例としてはその日が休日か否か、イベントの有無、予報を含めるのであれば天候（雨、曇り、晴れなど）があげられる。これらの特徴が似ている日は、人流の傾向も類似している可能性が高いため、このように選択的に学習データを用いて予測モデルを作成して予測することで、1日以上前に、対象日の人流を精度良く予測することが可能と考えられる。

## 5. 実データを用いた評価

### 5.1 評価データ

まず、評価データ準備のため、実際に商業施設において LRF システム [17] を用いて人流軌跡データを計測した。対象となる施設は3フロアあり、第1フロアは6、第2フロアは4、第3フロアは3つのエリアに分割されている。このエリアは、当該施設の空調制御単位に合わせて設定されている。対象エリアの詳細は後述する。測定期間は2018年の65日間だが、連続した65日間ではなく、途中で1日以上データの欠損期間が複数ある。測定日のうち土・日曜日は20日、残りの平日45日のうち振替休日を含む祝日は4日である。なお、本評価における人流予測精度目標は、ビル管理専門家の意見から誤差率20%以内とする。

次に、評価データとなる、人流軌跡データからの人流データ算出方法について述べる。人流データは要件で述べたように方向別の移動人数およびその平均速度とし、各測定日の7時から23時の中で30分の時間窓で算出した。さらに、エリア内において人は蛇行や停止といった行動をとることも考えられる。そこで本稿では簡略化のため、各時間窓、エリアにおいて計測された各通行者IDに対し、最初に測定された点と最後に測定された点の座標のみを抽出し、その2点から移動ベクトルを算出する。そしてその移動ベクトルのうち、東西南北で最も大きく動いた方向を移動方向とした。このような手法を用いることで、大量かつ多様な人流軌跡データに対して容易に、かつ施設管理に必要なエリアごとの統計レベルでの人流を算出することができる。算出例を図3に示す。上記の方法で計34方向を予測対象とした。各エリアの位置関係と対象とした方向の概




図3 人流の算出例

Fig. 3 Example of people flow calculation.

略を図4に示す。図4における青線はエリア外への開口部であり、エリアどうしの隣接点はすべて通過可能である。

### 5.2 評価方法

本稿では方向別の移動人数と平均速度は独立に予測し、評価することとした。提案手法における日ごとの特徴量として、商業施設では休日と平日、休日の何日目か、あるいは休前日かといった属性で人流傾向が変わることが想定されるため、休日か否かの2値を採用し、考慮する前後の日数  $s = 1$  とした。  $s = 1$  とした理由は、本評価では前述のとおり限られた日数の実測データのみを利用しており、  $s$  が大きくなると選択されるデータ数が極端に少なくなるか、または実際には特徴が近くないデータが最も近いデータとして選択されることを避けるためである。なお、  $k_{min} = 3$  とした。具体的には、平日である金曜日を予測対象とした場合は、前日が平日、次の日が休日となる平日のデータを主に用いてモデル作成を行う。また説明変数としては、あるエリアの方向別の移動人数または速度を予測する際は、上記提案アルゴリズムに沿って選択された、同一エリア・方向における移動人数または速度をそれぞれ用いた。また、提案手法での予測モデルは多重共線性を回避できるとされる Partial Least Square (PLS) 回帰モデルを用いた。

評価では、取得した65日分のデータのうち、全体の80%にあたる最初の52日と残り20%となる最後の13日に2分割した。そして、前者を学習用データセット、後者を予測用データセットとして、予測用データセットに含まれる各日に対し、各日の特徴に基づいて学習用データセットからデータを選択して予測モデルを作成したうえで人流を予測し、予測用データセットに含まれる当該日の人流実測値と比較した。各データセットにおいて、提案手法で  $s = 1$  とした際の休日(1)か否か(0)の特徴ベクトルごとの日数(データ数)を表2に示す。表2より、提案手法における説明変数は最小で2、最大で19となる。

比較のため、提案手法(JIT + Context)と同様の局所 PLS 回帰モデルを対象日の休日/平日のみで構築・予測す

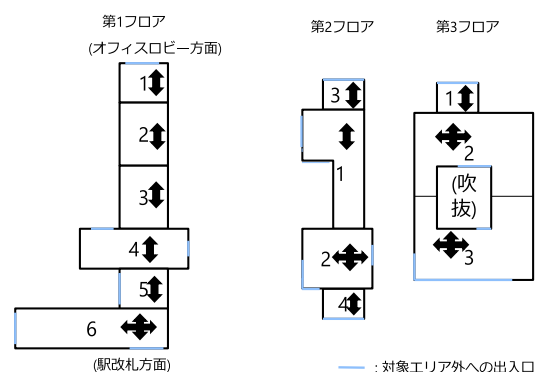


図4 各フロア、エリアの位置関係と対象とした方向の概略

Fig. 4 Floors, areas and target directions in this paper.

表 2 各データセットにおける特徴ベクトルごとの日数

Table 2 Statistics of feature vector on each day in each dataset.

特徴ベクトル	学習用データセット	評価用データセット
[0, 0, 0]	20	4
[1, 0, 0]	7	2
[0, 1, 0]	0	0
[0, 0, 1]	6	2
[1, 1, 0]	8	2
[0, 1, 1]	8	2
[1, 1, 1]	3	1
合計	52	13

る手法 (JIT + 1day), 対象日とその前後 1 日の休日/平日をカテゴリ変数として 1 つの PLS 回帰モデルを学習・予測する手法 (Single + Context), 対象日の休日/平日のみをカテゴリ変数として 1 つの PLS 回帰モデルを学習・予測する手法 (Single + 1day), 対象日とその前後 1 日の休日/平日をカテゴリ変数とし, カテゴリ変数を扱いやすい木構造を持つ 1 つの XGBoost モデルを学習・予測する手法 (XGB) でもそれぞれ評価を行い, 結果を比較した. なお JIT とは, 局所モデル構築の別名である Just-in-Time モデリングの略である. 比較の際, 提案手法と各比較手法の予測誤差率に対して対応ありの一要因分散分析を実施し, 有意となった場合はさらに Tukey 法で各手法間の多重比較を行った.

なお, PLS 回帰を用いた全手法における次元数  $c$  は Wold's R Criterion を 1.0 と設定し自動選択した. また, XGB におけるハイパーパラメータとして, 学習率=0.1 とし, 木の深さの最大値は [5, 10, 15, 20], サブサンプル抽出の割合は [0.5, 0.8], 各木を生成するための列におけるサブサンプルの割合は [0.5, 0.8] から, グリッドサーチを用いて最適なハイパーパラメータを選択した.

### 5.3 評価結果

全予測対象日および方向の結果として, 図 5 に方向別移動人数の, 図 6 に方向別平均速度の各手法における予測誤差率の平均と標準偏差をそれぞれ示す. 一要因の分散分析および検定結果, 方向別移動人数, 平均速度の両方で手法間の平均値の差は高度に有意 ( $p < 0.01$ ) となった. そのため, それぞれに対し Tukey 法で各手法間の多重比較を実施し, 有意差 ( $*: p < 0.05, **: p < 0.01$ ) の有無を評価した. なお, 方向別移動人数予測において, PLS 回帰の次元数  $c$  は JIT + Context では最小 1, 最大 9, JIT + 1 day では最小 2, 最大 10 であった. また方向別平均速度予測において, PLS 回帰の次元数  $c$  は JIT + Context, JIT + 1 day とともに最小 1, 最大 10 であった.

予測対象日ごとの結果として, 図 7 に方向別移動人数の, 図 8 に方向別平均速度の各予測対象日の予測誤差率の

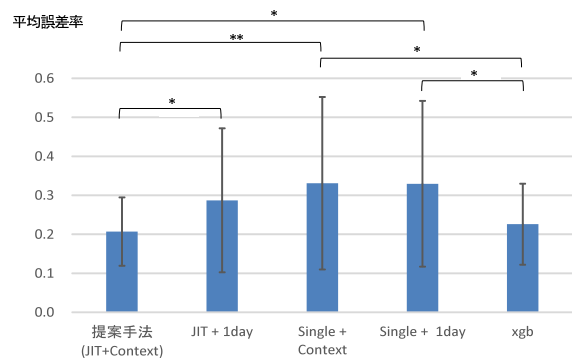


図 5 全予測対象日および方向における移動人数の予測誤差率 (平均 ± 標準偏差)

Fig. 5 Error ratio in prediction of number of moving people for all direction and day.

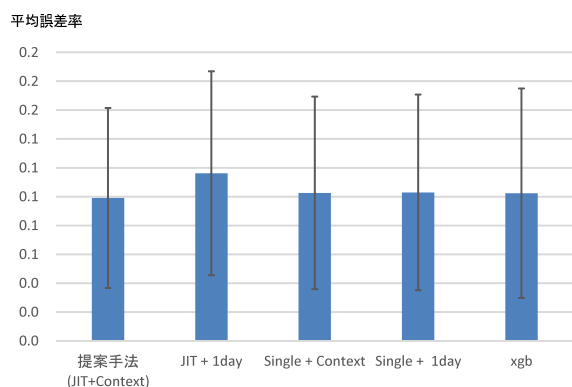


図 6 全予測対象日および方向における平均移動速度の予測誤差率 (平均 ± 標準偏差)

Fig. 6 Error ratio in prediction of speed of moving people for all direction and day.

平均と標準偏差をそれぞれ示す. なお, 対象日ごとの結果について, 対象日, 手法の 2 要因で分散分析を実施した結果, 移動人数, 平均速度の両方において, 対象日, 手法の両方において平均誤差率に高度に有意 ( $p < 0.01$ ) な差が見られた. そのため, 事後検定として対象日ごとに多重比較を実施したが, 移動人数, 平均速度の両方において有意な差は見られなかった.

また, 駅とオフィスロビーの間に位置する第 1 フロアと, 店舗が入居するのみの第 2, 3 エリアでの結果の違いを明らかにするため, 図 9 に方向別移動人数の, 図 10 に方向別平均速度の各手法における, 第 1 フロアと第 2, 3 フロアそれぞれでの予測誤差率の平均と標準偏差をそれぞれ示す. なお, 対象フロアごとの結果について, 対象フロア, 手法の 2 要因で分散分析を実施した結果, 移動人数, 平均速度の両方において, 対象フロア, 手法の両方において平均誤差率に高度に有意 ( $p < 0.01$ ) な差が見られた. そのため, 事後検定として対象日ごとに多重比較を実施し, 有意差 ( $*: p < 0.05, **: p < 0.01$ ) の有無を評価した.

具体的な予測結果として, 図 11 に 2 日目の第 1 フロア, エリア 1 の北方向への移動人数の予測結果, 図 12 に 2 日




図 7 方向別移動人数の日別予測誤差率

Fig. 7 Error ratio in prediction of number of moving people for each direction and each day.

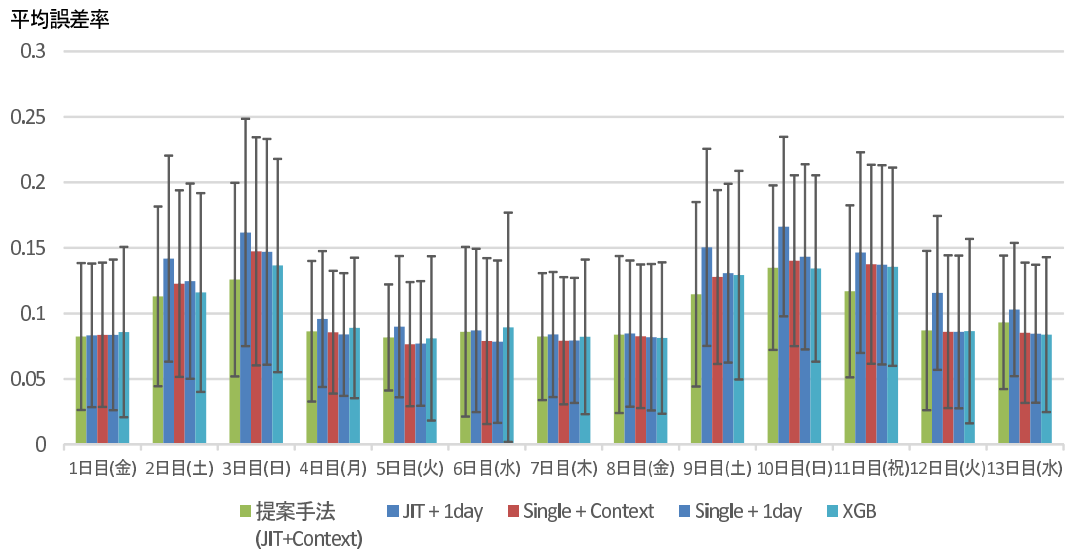


図 8 方向別平均速度の日別予測誤差率

Fig. 8 Error ratio in prediction of speed of moving people for each direction and each day.

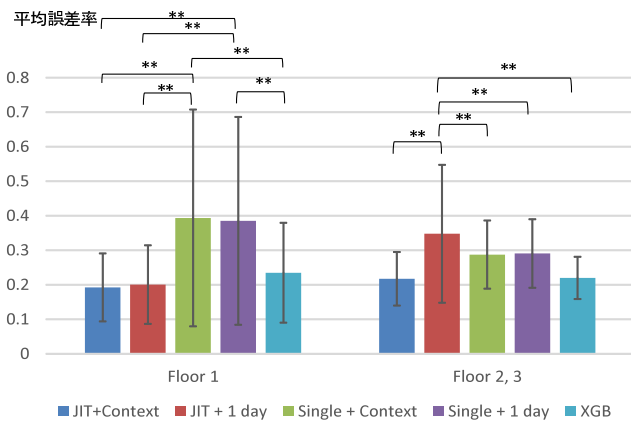


図 9 方向別移動人数のフロア別予測誤差率

Fig. 9 Error ratio in prediction of number of moving people for each floor.




図 10 方向別平均速度のフロア別予測誤差率

Fig. 10 Error ratio in prediction of speed of moving people for each floor.

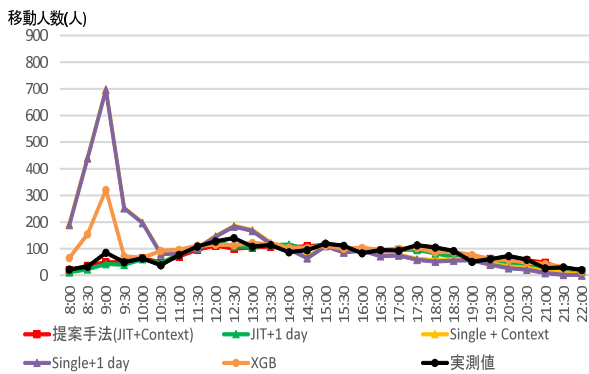


図 11 2日目の第1フロア, エリア1の北方向への移動人数の予測結果

Fig. 11 Predicted and measured number of people going to north direction at area 1 on 1st floor, day2.

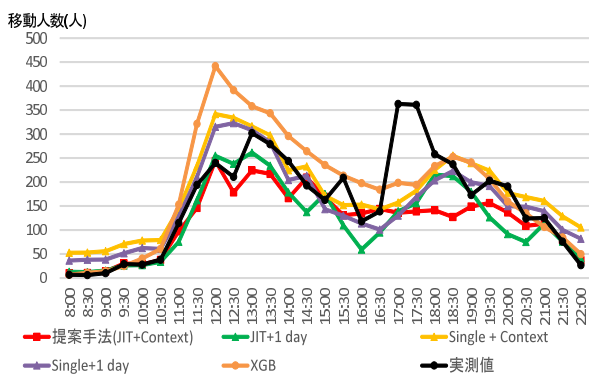


図 12 2日目の第3フロア, エリア3の南方向への移動人数の予測結果

Fig. 12 Predicted and measured number of people going to south direction at area 3 on 3rd floor, day2.




図 13 2日目の第1フロア, エリア1の北方向への平均速度の予測結果

Fig. 13 Predicted and measured average of speed of people going to north direction at area 1 on 1st floor, day2.

目の第3フロア, エリア3の南方向への移動人数の予測結果, 図 13 に2日目の第1フロア, エリア1の北方向への平均速度の予測結果, 図 14 に2日目の第3フロア, エリア3の南方向への平均速度の予測結果をそれぞれ示す.




図 14 2日目の第3フロア, エリア3の南方向への平均速度の予測結果

Fig. 14 Predicted and measured average of speed of people going to south direction at area 3 on 3rd floor, day2.

## 5.4 考察

### 5.4.1 方向別移動人数の予測

図 5 より, 全体として提案手法のほうが比較手法より誤差の少ない方向別移動人数の予測が可能であり, また比較手法の中でも単一の PLS モデルで予測した結果 (Single + Context, Single + 1 day) より, 予測日の平日・休日を考慮してモデルを作成・予測したほうが有意に精度が高いこと, 単一の XGBoost モデルで予測した結果は, 単一の PLS 回帰モデルや前後日を考慮せず局所モデル構築で予測した手法より精度が高いが, 提案手法の方がさらに平均精度が高いこと, ただし結果に有意差がないことが分かる. さらに, 精度目標である誤差率 20%以内は, 提案手法のみがほぼ満たしていることが分かる. 参考までに, 提案手法と XGB の結果のみを対応あり t 検定で一对比較した場合, 1%の水準で有意差が見られた. このため, 本稿での評価用データのみでは提案手法が XGB より優れているとは結論づけることはできないが, 後述のように今後評価用データの期間を長くすることで, 提案手法が有意に優れた手法となる可能性があると考えられる.

次にこのような結果となった要因について考察する. 図 7 より, 提案手法の効果が大きい傾向にあるのは土日祝日, およびその前後である 1 日目 (金), 2 日目 (土), 3 日目 (日), 4 日目 (月), 10 日目 (日), 11 日目 (祝), 12 日目 (火) であることが分かる. また図 9 より, 駅とオフィスを結ぶ動線がある第 1 フロアでは局所モデルを構築する提案手法と従来手法 (JIT + 1day) が同程度の精度である反面, そのような動線がない第 2, 3 フロアについては, JIT+1 day より単一のモデルで予測する従来手法 (Single + Context, Single + 1day, XGB) の方が精度が高いことが分かる. これは一般に, 駅からオフィスへの通勤客と考えられる動線は平日と休日の差が非常に大きいことが想定されるが, 第 2, 3 フロアは買い物客が主であり, 平日と休日の違いが通勤客の動線ほど大きく違いはないうえ, その前後の日での違い, たとえば休日前であれば比較的混雑



し、連休最終日であれば連休日初日などより人が少ない、といった違いも生じうるため、このような結果になったと考えられる。実際、図 11 における 2 日目 (土) における第 1 フロア、エリア 1 の北方向での予測結果では、単一モデルの従来手法では 9 時前後に実測値より大幅に大きい値を予測しているが、提案手法を含む局所モデルを構築した手法での予測値は実測値に近い値となっており、通勤客が多く休日と平日の差が極端なケースでは、有意差は見られなかったものの、木構造を持つ XGBoost での単一モデルの手法と比較しても、提案手法のような局所モデル構築が有効な可能性がある。他方、同日であっても図 12 における第 3 フロア、エリア 3 の南方向での予測結果ではそのような違いは見られないこと、単一モデルであるが前後の休日平日を考慮した Single+Context も特に夜の時間帯において実測値に近い値を予測していることも、上記の考察が正しいことを示唆していると考えられる。

まとめると、方向別移動人数の予測において、提案手法は PLS 回帰を用いた比較手法と比べ、全体としては有意に高精度な予測ができること、XGB を用いた比較手法と比べると有意差はなかったが、より精度が高い可能性があることが分かった。その要因として提案手法は、休日と平日で大きく変わる通勤に関する人流には局所モデル構築によって、通勤ほど極端な違いはないが休日・平日だけでなくその前後も影響する買い物客の人流については、前後の休日・平日も考慮することにより、それぞれ高精度な推定を実現できたと考えられる。

#### 5.4.2 方向別平均速度の予測

図 6 より、方向別平均速度は全体として提案手法のほうが比較手法より誤差の少ない方向別移動人数の予測ができる可能性があるが、多重比較での有意差が見られないことが分かる。また、有意差は見られないものの、提案手法と同じく局所モデルを構築した比較手法 (JIT + 1day) より、単一モデルを用いた比較手法 (Single + Context, Single + 1day, XGB) のほうが精度が高い可能性があるといえる。なお、比較手法を含むすべての手法が精度目標を満たしているが、誤差率が 10% 前後と全体として方向別移動人数より小さいのは、移動人数と比較して平均速度の変化が小さいためと考えられる。

次にその要因について考察する。図 8 より、提案手法の効果が大きい傾向にあるのは土日祝日である 2 日目 (土)、3 日目 (日)、9 日目 (土)、11 日目 (祝) であることが分かる。また図 10 より、駅とオフィスを結ぶ動線がある第 1 フロアでは局所モデルを構築する提案手法と従来手法 (JIT + 1day) で有意差はないものの平均値の差が相対的に大きい反面、単一モデルを用いる比較手法との差は相対的に小さいこと、またそのような動線がない第 2、3 フロアについては、提案手法は最も精度が良いものの、同様に他の比較手法とは有意差がないことが分かる。これは、方向別平均速

度は移動人数と異なり、必ずしも休日・平日で大きな人流の違いが生じず、かつ通勤、買い物といった客層による顕著な違いもあまりなく、提案手法の効果が限定的であったことを示唆している。ただ、土曜日と日曜日の違い、3 連休の初日と最終日といった違いはあるため、これらを考慮しつつ局所モデルを構築した提案手法が、全体として最も平均的な精度が高いという結果になったと考えられる。実際、図 13 における 2 日目 (土) における第 1 フロア、エリア 1 の北方向での予測結果では、すべての手法において予測結果の差が小さいが、同日であっても図 14 における第 3 フロア、エリア 3 の南方向での結果では、手法間の結果に差があり、かつ提案手法が他手法よりわずかであるが良い予測結果を示していることが、上記の考察が正しいことを示唆していると考えられる。

まとめると、方向別平均速度の予測において、提案手法は比較手法と比べ、全体としては高い精度の予測結果が出たが、統計的な有意差はないことが分かった。その要因として、必ずしも休日・平日で大きな人流の違いが生じず、かつ通勤、買い物といった客層による顕著な違いもあまりなく、提案手法の効果が限定的であったことが考えられる。

#### 5.4.3 提案手法に関するまとめ

結論を述べるため、本稿の課題を再掲する。

施設内の各エリアにおける数十分ごと方向別移動人数と速度を、予測日の 1 日以上前のデータのみから予測可能か否か。

実データを用いた結果および考察より、提案手法は PLS 回帰を用いた比較手法より高精度に予測できることが明らかになった。これは商業施設では、平日と休・祝日、あるいはその前後の日で、あるいは客層といったフロアが持つ特性に違いによって、人流が大きく変わることが原因であり、提案手法は想定どおりの効果を発揮できたと評価することができる。一方で、XGBoost を用いた比較手法より提案手法は精度が高い傾向が見られるものの、有意差が見られなかったため、今後さらなる検証が必要と考えられる。

よって、上記課題については、可能と結論づけられる。

今回は平日・休日の分類のみを特徴量として学習データを選択して予測モデルを作成し予測したが、今後は来場者数に影響する各日の 1 時間ごとの気温や天候 (晴れ、曇り、雨) も特徴量として扱い、時間ごとの天候が近い日のデータのみを選択して予測モデルを作成することで、精度の向上が見込まれると考えられる。また、今回は用いるデータ数が限られることもあり、 $s = 1$  として評価を行ったが、長期連休を含む長期間のデータを用いつつ、 $s \geq 2$  で予測モデルを作成することで、4 連休以上の長期連続休暇の影響を考慮した、より高精度な予測が可能になると考えられる。

さらに、本稿では学習データが 52 日間のみであったた

め、表 2 で示したように、 $s = 1$  であっても [休日, 休日, 休日] の学習用データが 3 日分しかないケースや、[平日, 休日, 平日] のように 1 日もないケースが見られた。後者のケースについては、年によっては 1 年に 1 回も現れないケースもあるため、完全一致ではなく類似した特徴ベクトルによるデータ選択と学習・予測によって対応せざるをえない一方、前者のケースはデータセットの拡大によって解決する可能性がある。より具体的には、もし学習用データセットの日数が 2 倍になれば、[休日, 休日, 休日] のケースも約 2 倍の 6 日となり、学習モデル作成時に特徴ベクトルが完全一致した 5 日分のデータを説明変数として用いることができ、2 日分しか用いることができなかった本稿のケースより精度の高いモデルの作成が期待できる。よって本手法は、100 日以上学習データがあれば、多くの特徴ベクトルのパターンにおいて精度の高いモデル作成と予測ができると考えられる。またそのような場合、提案手法はより多くのデータを学習に用いることができるようになるためさらなる精度の向上が期待でき、従来手法である XGB より有意に高い精度で予測できる可能性があると考えられる。

## 6. 結言

本稿では、商業施設のような不特定多数の人間が集まる施設の管理・運営を支援するため、日常の管理業務に役立つよう、その施設の中で起こる人流である方向別通過人数や速度を予測する常時型人流予測手法を提案した。本稿の貢献は以下のとおりである。

- 施設における人流予測の要件として、設備稼働準備や人およびモノの調達観点から、エリアごとの方向別通過人数や速度といった予測すべきデータの粒度、時間窓長と予測対象時点を明確化した。
- 上記の制約に加え、多くの施設では休日、平日やその前後では人流傾向が大きく異なりうることに着目し、予測対象日およびその前後の属性に基づき、学習データを選択して局所モデルを作成後、予測する手法を提案した。
- 提案手法を実際の商業施設において計測したデータへ適用した結果、単一モデルを用いる比較手法や前後日を考慮せず局所モデルを構築する比較手法と比べ、平均速度の予測では差は見られなかったが、方向別移動人数では高い精度で予測でき、特に休日やその前後日によって人流が大きく異なるフロアやエリアに対してより有効であることが明らかになった。ただし、XGB を用いた比較手法には精度で優っているが有意差が見られなかったため、XGB に対する優位性に関してはより長期間のデータを用いたさらなる検証が必要である。

今後の課題として、長い連休を含むようなより長期間を

学習対象としたケースや、複数日間のイベントが開催されるようなケースにおける提案手法の追加評価および改良があげられる。

## 参考文献

- [1] Araszkiwicz, K.: Digital Technologies in Facility Management – The state of Practice and Research Challenges, *Procedia Engineering*, Vol.196, pp.1034–1042 (2017).
- [2] Teixeira, T and Savvides, A.: Lightweight people counting and localizing for easily deployable indoors wsns, *IEEE Journal of Selected Topics in Signal Processing*, Vol.2, No.4, pp.493–502 (2008).
- [3] Panangadan, A., Mataric, M. and Sukhatme, G.S.: Tracking and Modeling of Human Activity Using Laser Rangefinders, *International Journal of Social Robotics*, Vol.2, pp.95–107 (2010).
- [4] Shackleton, J., VanVoorst, B. and Hesch, J.: Tracking people with a 360-degree lidar, *Proc. 7th IEEE AVSS*, pp.420–426 (2010).
- [5] Kang, D., Ma, Z. and Chan, B.A.: Beyond Counting: Comparisons of Density Maps for Crowd Analysis Tasks - Counting, Detection, and Tracking, *IEEE Trans. Circuits and Systems for Video Technology*, Vol.29, No.5, pp.1408–1422 (2019).
- [6] Longo, E., Redondi, A.E. and Cesana, M.: Accurate occupancy estimation with WiFi and bluetooth BLE packet capture, *Computer Networks*, Vol.163, No.9, 106876 (2019).
- [7] Arief-Ang, I.B., Hamilton, M. and Salim, F.D.: A scalable room occupancy prediction with transferable time series decomposition of co2 sensor data, *ACM Trans. Sensor Networks (TOSN)*, Vol.14, No.3-4, pp.1–28 (2018).
- [8] Zou, H., Zhou, Y., Yang, J. and Spanos, C.J.: Device-free occupancy detection and crowd counting in smart buildings with WiFi-enabled IoT, *Energy and Buildings*, Vol.174, No.1, pp.309–322 (2018).
- [9] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L. and Savarese, S.: Social LSTM: Human trajectory prediction in crowded spaces, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.961–971 (2016).
- [10] Ziebart, B.D., Ratliff, N., Gallagher, G., Mertz, C., Peterson, K., Bagnell, J.A., Hebert M., Dey A.K. and Srinivasa S.: Planning-based prediction for pedestrians, *Proc. 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.3931–3936 (2009).
- [11] Ueda, N. and Naya, F.: Spatio-temporal multidimensional collective data analysis for providing comfortable living anytime and anywhere, *APSIPA Trans. Signal and Information Processing*, Vol.7, pp.1–17 (2018).
- [12] Box, G.E.P. and Pierce, D.A.: Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models, *Journal of the American Statistical Association*, Vol.65, No.332, pp.1509–1526 (1970).
- [13] Adamopoulou, A.A., Tryferidis, A.M. and Tzovaras, D.K.: A context-aware method for building occupancy prediction, *Energy and Buildings*, Vol.110, No.1, pp.229–244 (2016).
- [14] Erickson, V.L., Carreira-Perpinan, M.A. and Cerpa, A.E.: Occupancy Modeling and Prediction for Build-

ing Energy Management, *ACM Trans. Sensor Networks (TOSN)*, Vol.10, No.3, Article No.42 (2014).

- [15] 環境省：ZEB Portal 建築物のエネルギー消費状況，入手先 (<http://www.env.go.jp/earth/zeb/detail/04.html>) (参照 2019-12-09).
- [16] The International Organization for Standardization, ISO 7730:2005 Ergonomics of the thermal environment – Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria, available from (<https://www.iso.org/obp/ui/#iso:std:iso:7730:ed-3:v1:en>) (accessed 2019-12-09).
- [17] 日立情報通信エンジニアリング，人流計測サービス，入手先 (<http://www.hitachi-ite.co.jp/br/br07.html>) (参照 2019-12-09).



角田 啓介 (正会員)

2009年早稲田大学理工学部経営システム工学科卒業。2011年同大学院修士課程修了。同年NTT入社。サイバーソリューション研究所，サービスエポリユーション研究所にて，ホームICTサービス基盤，生体計測および生体情報解析に関する研究に従事。

2016年よりNTTコムウェアにて，企業業務を支援する新規ICT技術およびサービスの企画・開発に従事。2019年筑波大学大学院システム情報工学研究科知能機能システム専攻博士後期課程修了。現在，NTT サービスエポリユーション研究所研究主任。機械学習やセンサデータを活用したスマートシティ向けエリアマネジメント支援に関する研究開発に従事。電子情報通信学会会員。博士（工学）。



秦 崇洋

2006年京都大学大学院情報学研究科を修了し，同年NTT未来ねっと研究所へ入所。ユビキタスサービスプラットフォームの研究開発に従事。現在，NTTスマートデータサイエンスセンタにて，IoTデータ価値化に関する研究開発に従事。電子情報通信学会会員。



尾花 和昭

1997年早稲田大学大学院修士課程修了。同年日本電信電話株式会社入社。以降次世代エッジシステム，ホームICT，ネットワーク仮想化の研究等に従事。現在，NTT未来ねっと研究所にて，自律制御光リンクシステムの研究開発に従事。電子情報通信学会，IEEEの各会員。

研究開発に従事。電子情報通信学会，IEEEの各会員。