

状態依存サービス時間分布を持つ $M_t/G/\infty$ モデルを用いた 水族館混雑制御のデジタルツイン構築について

池田拓人¹, 谷田桜子², 野崎滋人³, 柳澤大地^{2,4}, 西成活裕^{2,4,5}, Feliciani Claudio²
1. 東京大学 工学部 航空宇宙工学科, 2. 東京大学 大学院工学系研究科 航空宇宙工学専攻, 3. 海遊館
4. 東京大学 モビリティ・イノベーション連携研究機構, 5. 東京大学 先端科学技術研究センター

概要：本研究では、博物館などの施設を対象に、「待っている人数」「サービス中の人数」「サーバ数」を明示的に特定できない状況でも混雑を分析できるモデルを提案する。展示空間内の人数の推移を無限サーバ型待ち行列として表現し、さらに混雑度に応じてサービス時間分布が変化する仕組みを組み込んだ。理論面では、この混雑度依存型無限サーバモデル $M_t/G_d/\infty$ について、系内客数過程を記述する Volterra 型積分方程式を導出した。また、定常状態において、この系の入力である展示への到着率と、展示内の混雑度の対応関係を解析した。さらに大阪・海遊館で得られた 2024 年 8 月 3 日～9 月 30 日の実測データを用いて、各展示を 12 通りのサービス時間分布の型に分類し、解析的に混雑を制御できる指標を定義・導出した。これらを元に、系内客数過程をシミュレーションで再現することで、モデルの適用妥当性を検証した。その結果、提案モデルは実際の滞在時間と系内客数過程を良好に再現し、展示ごとの特性に応じた混雑制御やその設計に有効な評価基盤となることを示した。最後に、これらの展示モデルを接続することで、施設全体の混雑を再現するデジタルツインの構想を示した。

1. 序論

博物館などの観覧型の展示施設では、人気展示に来館者が集中すると滞留や待ち列が発生し、鑑賞体験の質や満足度が低下するとともに、入館制御や人員配置といった運営計画も立てにくくなる [1]。従来、こうした計画は経験に大きく依存しており、混雑状況の変化に対するロバストな計画立案や、運営方策の最適化を行う上での指針が十分とはいえなかった。このため、再現性のある定量的指標と数理モデルにもとづき、混雑と滞在時間の関係を明示的に取り込んだ運営計画の設計が求められている。

本研究では、混雑要因を施設構造と展示の人気に分類し [2]、そのうち展示の人気に起因する混雑に着目して、「混雑が滞在時間に与える影響」と「混雑の制御方法」を定量的に記述する新たな数理モデルの構築を目指す。

本研究で用いた数理モデルのベースとなっている待ち行列の $M_t/G/\infty$ モデルは、無限サーバ型待ち行列モデルの一種であり、その基本的な性質については、Eick ら [3] により解析されまとめられている。また、同じ著者らにより、任意の非定常ポアソン到着に従う到着者数の時系列に対する、振幅倍率・位相遅れなどの系内客数過程の応答特性が、サービス時間分布のフーリエ変換を用いて求められることが示されている [4]。さらに、Glynn ら [5] により、サーバ数を無限としても、有限の場合に対するよい近似となることが知られており、特に混雑度が非常に高い場合や、到着率が時間変化する場合に有用であることが示されている。逆問題の観点では、Li ら [6] により、客の退出時刻の観測データから、サービス時間分布を推定する手法が提案されている。また、Goldenshluger ら [7] は、系内客数過程のみの観測データからサービス時間分布をどの程度まで推定することができるかを理論的に解析した。応用の面では、医療システムの人員配置に応用されたり [8]、逆問題の理論と組み合わせ、個体数しか観測できない昆虫の個体群に対して、いつ何匹生まれて、何匹死んだかの推定に応用された例 [9] もある。

以上のように、 $M_t/G/\infty$ モデルについては、その理論的性質や逆問題に関する研究がこれまでに数多くなされている。一方で、これらのモデルを実際の人流や滞在行動の解析に適用するためには、モデルの前提に対応した観測データをどのように取得するかが重要な課題となる。とりわけ、個々の客を識別せずに系内客数や滞在時間に関する情報を得る必要がある施設においては、非侵襲的かつ継続的な観測手法が求められる。近年、センサ技術の進展により、このような要件を満たす観測が可能となっており、その中でも本研究で用いた BLE (Bluetooth Low Energy) センサは、安価で設置が容易かつ、鑑賞を妨げないため、人流解析への応用が進められている。

BLE センサは専用のビーコンと共に用いれば、ビーコンを携帯している個人の展示での滞在時間や移動順序などを把握できるため、博物館などで来館者行動の計測に広く利用されている。例えば

Centorrino ら [10] は, Borghese 美術館にてビーコンの受信ログから部屋単位の滞在時間と動線を推定し, 館内混雑を再現するデジタルツインを構築している. また, Kawaguchi ら [2] は水族館において, ビーコンデータから展示前滞在を推定し, 混雑が鑑賞時間を短縮することを実測的に示している. さらに, Onofri ら [11] はビーコンのノイズや欠損を補正する手法を提案し, 少数の BLE センサ環境でも, 部屋レベルで高精度の位置推定が可能であることを示している.

このようなビーコンを用いれば, 個人の入退場時刻を高精度に取得できる一方で, ビーコンの配布や回収, データ取得には手間とコストがかかる. デジタルツインのモデル構築の際は滞在時間のモデル化のために必要であるが, 実装後の運営計画の立案や混雑制御の際にも使用できるとは限らない. その際には, BLE センサ単体で取得可能な, Bluetooth を ON にしているスマホ利用者数を展示前の人数の指標として用いて混雑制御を行うことが望ましい. しかし, BLE センサは「その場所に何人いたか」という情報は高頻度で取得できる一方, 個人の入退場の時刻は取得できず, その場の「鑑賞中の人数」と「待機中の人数」を区別できない.

そこで本研究では, 粗い観測データにも適用できる新たな待ち行列モデルを構築し, 混雑解析手法を提案する. そして, 大阪・海遊館 [12] で実験した BLE センサのデータからパラメータ推定とモデルの適用妥当性の検証を行うとともに, 各展示モデルを統合した施設全体のデジタルツイン構築と, それに基づく混雑制御・運営計画への応用可能性を示す.

2. モデル提案

本研究で提案するモデルは, 観覧型展示施設における各展示を対象とする. ここでの観覧型展示施設とは, 来館者が各展示を順路に沿って巡回しながら, 自分のペースで鑑賞するような施設を指し, 主に博物館や美術館, 水族館などが該当する (図 1(左) 参照). その中での各展示, 例えば美術館であれば絵画や彫刻, 水族館であれば水槽などが, 本研究でモデル化する対象となる (図 1(右) 参照).

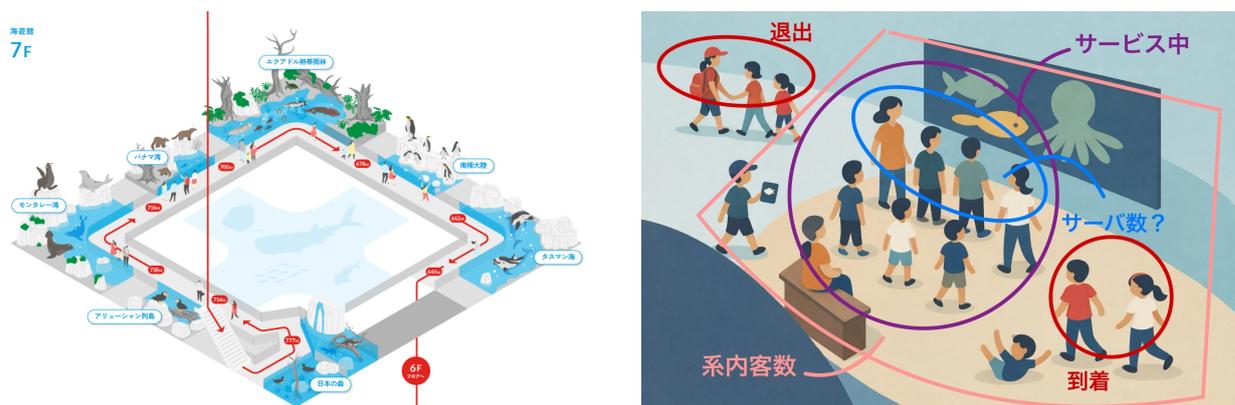


図 1: このモデルの対象となる観覧型展示施設の例 (海遊館 7F の館内図)(左) と, このモデルを適用する展示の例 (右)

このような展示を 1 つの単位とする系に, 人が到着して「待機」「鑑賞 (サービスを受ける)」「退出」という流れは, 待ち行列モデルと類似しており, 待ち行列モデルを用いて混雑を表現・解析できると考えられる. しかし, 従来の到着が非定常ポアソン過程で, サービス時間分布が指数分布の, 有限サーバ型待ち行列モデル $M_t/M/s$ は, 展示における「鑑賞中の人数」「待機中の人数」「サーバ数」と, このような施設特有のサービス時間分布を表現できない. また, BLE センサが提供する人数ベースの粗い観測との接続も困難である.

そこで本研究では, サーバ数を事実上無限とみなした無限サーバ型待ち行列を採用する. 無限サーバ型であれば混雑が極端に高まっても理論的前提が破綻せず, 到着後すぐにサービスが開始されるため, 「鑑賞中の人」と「待機中の人」, 「サーバ数」を定義する必要がない. このため, BLE センサで観測される系内客数過程 $N(t)$ と自然に対応づけることができる.

一方で, 無限サーバ型ではサービスが到着直後に開始されるため, 待ち列が存在せず, このままでは混雑による滞在時間の伸びが待ち時間として表現されない.

そこで、本研究では混雑の影響を「待ち列の延長」ではなく「サービス時間の伸長」として取り込む。展示ごとに、実験期間で観測された最大人数 N_{\max} を用いて、混雑度 d を

$$d(t) = \frac{N(t)}{N_{\max}} \quad (1)$$

と定義した。この混雑度に応じて、混雑が全くないときの基準サービス率 μ_0 が混雑度影響関数 $g(d)$ で補正された実効サービス率

$$\mu_d = \mu_0 g(d), \quad 0 < g(d) \leq 1 \quad (2)$$

を用いることで、サービス時間分布が系内の状態、系内客数に依存するように拡張する。また、サービス時間分布には、観覧型施設特有の滞在時間分布を表現するために、一般分布 G を用いる。ただし、サービス時間分布が混雑度に依存することを明示するために、 G_d と表記する。

以上を踏まえ、非定常ポアソン到着と状態依存サービス時間分布を持つ無限サーバ型待ち行列 $M_t/G_d/\infty$ を、このような施設での混雑解析のモデルとして提案する。この $M_t/G_d/\infty$ モデルにより、展示の魅力度や混雑による滞留効果、その解析・制御を可能にする混雑解析手法を構築する。

3. モデル解析

$M_t/G_d/\infty$ モデルの系内客数過程を導出する。

$M_t/G/\infty$ において系内客数過程を表す式として知られる、系内客数の期待値 $n(t)$ についての Volterra 型積分方程式は以下の通りである [3]。

$$n(t) = \int_0^t \lambda(t-a) S(a) da. \quad (3)$$

ここで、 $\lambda(t)$ は時刻 t における到着率、 $S(t)$ は生存関数である。

(1) で定義した混雑度より、(3) を変形して混雑度 $d(t)$ についての式が導かれる。

$$d(t) = \frac{1}{N_{\max}} \int_0^t \lambda(t-a) S(a) da \quad \because d(t) = \frac{n(t)}{N_{\max}}. \quad (4)$$

さらに (2) で定義した混雑度影響関数 $g(d)$ で補正された実効サービス率 μ_d を用いて (4) を以下のように書き直す。

$$\begin{aligned} d(t) &= \frac{1}{N_{\max}} \int_0^t \lambda(t-a) S(a; \mu_d) da \\ &= \frac{1}{N_{\max}} \int_0^t \lambda(t-a) S(a; \mu_0 g(d(t-a))) da. \end{aligned} \quad (5)$$

ここで、時刻 t に到着した客は、その到着直前の混雑度に応じたサービス時間分布に退場まで従い、その間に混雑度が変わっても、従うサービス時間分布は変化しないと仮定している。

定常状態における各パラメータの期待値を*を付けて表すこととし、(5) を計算すると以下のようになる。

$$\lambda^* = \frac{N_{\max} d^*}{E[T_{d^*}]} \quad (6)$$

ここで、 $E[T_{d^*}]$ は混雑度 d^* におけるサービス時間の期待値である。

この (6) により、定常状態における到着率と混雑度の対応関係を求めることができる。また、 λ^* が与えられたときに、それを満たす混雑度 d^* が存在するかどうかで、定常状態の存在を確認できる。

4. 制御指標の定義

前章で導出した (6) の右辺を最大にする混雑度 d_{\max}^* を導出すれば、流量が最大化し、利益も最大化されると考えられる。

ただし、この混雑度 d_{\max}^* では、来館者側の視点に立つと快適に鑑賞できる混雑度とは限らず、満足度が下がる可能性がある。そこで、来館者が快適に鑑賞できる混雑度の上限値として、「許容混雑度」を定義し、その値を各展示ごとに推定することを試みた。

Yoshimura ら [14] により、一定の混雑度までは混雑度に依存して滞在時間は長くなるが、ある閾値を超えると、逆に滞在時間が短くなることが示されている。これは一定の混雑度までは混雑度 0 の時のベースとなる鑑賞時間に加えて待ち時間が上乘せされるため滞在時間が長くなるが、ある混雑度を超える場合には、満足いく鑑賞をするための待ち時間が長すぎるため鑑賞時間を短縮して退出する来館者が増え、結果として滞在時間が短くなるのが原因と考えられる。実際、海遊館で行われた研究 [15] においても、混雑度が高い日には、閑散日に比べて鑑賞時間が短くなる傾向が確認されている。

以上より、後述する海遊館での実測データから混雑度ごとに滞在時間の期待値を推定し、プロットしてみると、図 2(左) にその一例を示すように、滞在時間が最大となる混雑度が存在することが確認された。このピークの位置を「許容混雑度」 d_{allow} として定義する。ここで、縦軸については、秘密保持の関係から、滞在時間の期待値を、この頂点での値で割った相対値で示している。そして、全ての展示に対してこれを行った。各展示での許容混雑度のヒストグラム (図 2(右) 参照) を見ると、多くの展示で 0.80 付近に集中していることが分かる。

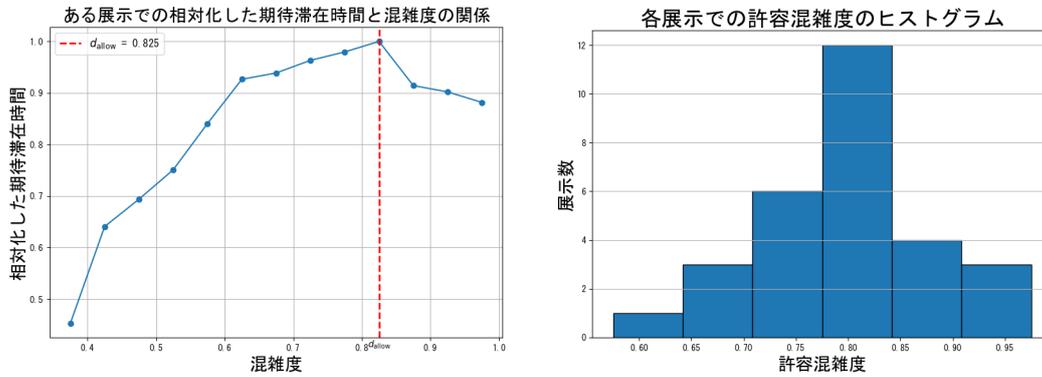


図 2: ある展示での期待滞在時間 (相対値)(左) と各展示での許容混雑度の分布 (右)

5. 一般分布の近似

ここまでは、サービス時間分布を一般分布 G として解析を進めてきた。しかし、ここからの解析ではサービス時間分布および混雑度影響関数 $g(d)$ を完全にノンパラメトリックには扱わない。これらを一般の関数として扱おうと、導出した理論式を閉じた数式として記述できず、(5), (6) の数値計算が困難になる。また、パラメータ推定が高次元かつ不安定になり過学習を起こしやすくなる。

そこで、サービス時間分布の確率密度関数には以下の表 1(左) の通り、指数分布, Erlang 分布, Weibull 分布を用いる。Erlang 分布は、指数分布の段階的な組み合わせで解釈でき、待ち行列理論でよく用いられる。Weibull 分布は、Erlang 分布と同等の柔軟性を持ち [13], 博物館特有のサービス時間分布を表現できる [10]。同様に、(2) の混雑度影響関数 $g(d)$ には、以下の表 1(右) の 4 つを用いる。

表 1: 分布型と混雑度影響関数の一覧

| 型 | 確率密度関数 $f(t)$ | 型 | 混雑度影響関数 $g(d)$ |
|------------------------------|--|--------|--|
| 指数分布型 $M_t/M_d/\infty$ | $f_1(t; \mu_d) = \mu_d \exp(-\mu_d t)$ | 線形減衰型 | $g_1(d) = 1 - \beta d$ |
| Erlang 分布型 $M_t/E_d/\infty$ | $f_2(t; \mu_d, k) = \frac{(\mu_d)^k t^{k-1}}{(k-1)!} \exp(-\mu_d t)$ | 反比例型 | $g_2(d) = \frac{1}{1 + \beta d}$ |
| Weibull 分布型 $M_t/W_d/\infty$ | $f_3(t; \mu_d, k) = \mu_d k (\mu_d t)^{k-1} \exp(-(\mu_d t)^k)$ | 指数減衰型 | $g_3(d) = \exp(-\beta d)$ |
| | | シグモイド型 | $g_4(d) = \frac{2}{1 + \exp(\beta d)}$ |

ここでパラメータ β は「その展示が混雑の影響をどれだけ受けやすいか」を表す感度パラメータであり、 $\beta = 0$ のときは混雑がサービス時間に影響しない場合に対応する。

また、線形減衰型では、混雑度が $1/\beta$ を超える場合にはサービス率が負になってしまうが、今回の推定ではそのような結果はなかった。もし、線形減衰型でパラメータを推定する際は $\beta \leq 1$ とすることで、サービス率が負になることを防ぐ必要がある。

これらを組み合わせた 12 通りの分類と推定したパラメータ値を用いて、展示ごとの性質を比較できるようにする。

6. モデル検証

本モデルの適用妥当性を検証するために、大阪・海遊館で 2024 年 8 月 3 日～9 月 30 日に実施した BLE センサ実験のデータを用いる。この期間中、館内の各展示付近に BLE センサを 29 台設置し、センサが検知した Bluetooth 信号の数を 10 秒間隔で記録した。各展示は一方通行の順路に沿って配置されており、前から順に 1～29 番と番号付けした。この際、電波の強さを表す RSSI (Received Signal Strength Indicator) が -100dBm 以下の弱い信号は、展示から遠い場所にいる人によるものとして除外した。このようにして検知した数を展示内の客数の指標として用いる。本研究では、各センサで検知した信号数を系内客数として用いた。例として展示 1 のある日の結果を図 3(左) に示す。

同時に、約 3000 人の協力者に BLE ビーコンを携帯してもらい、各センサが検知したビーコン ID と時刻から、来館者ごとの位置の変化を取得した。

まず、このビーコンデータを用いて、各展示におけるサービス時間データを取得した。ただし、ビーコンデータには欠損やノイズが含まれるため、次の前処理を行った。

まず、RSSI が -100dBm 以下の弱い信号を除外し、さらに、連続観測が 3 秒未満のセンサはノイズとして除去して、残ったデータは 1 秒間隔に補完して等間隔の時系列データを作成した。不自然な急激なセンサ切替は直前の値で補正し、5 秒以下の短い滞在は前のセンサのものとした。これにより、ノイズを除去した来館者の軌跡データを得た。

得られた時系列データに対し、同時に複数のセンサから観測がある場合、最も強い RSSI を取得したセンサを滞在している展示とみなし、各展示でのサービス時間を算出した。その例が図 3(右) である。縦軸はビーコンを検知して、現在滞在している展示番号であり、赤線が推定した来館者の滞在軌跡である。

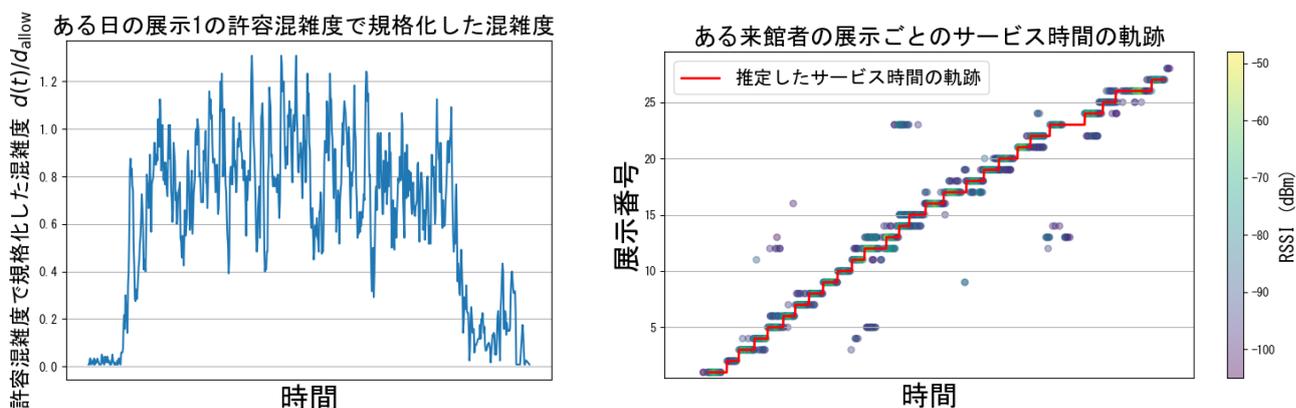


図 3: 展示 1 における、ある日の許容混雑度で規格化した混雑度の時系列データの作成例 (左) と、ビーコンによる来館者のサービス時間データの作成例 (右)

これに対し、12 通りのサービス時間分布と混雑度影響関数 $g(d)$ の組み合わせごとに、K-fold 交差検証と最尤推定法を用いてパラメータ推定を行った。

まず、各展示ごとのサービス時間データのうち、K-1 個のグループを訓練データとして用いてパラメータ推定を行い、残りの 1 個のグループをテストデータとして用いてモデルの適合度を全混雑度 (0～1) と高混雑度 (0.5～1) の 2 通りで評価した。高混雑度のデータ数は、全混雑度の 7～8 割程度であった。これを K 回繰り返す、その平均適合度を各モデルの適合度とした。

適合度の評価指標として、観測した滞在時間データから作成した経験分布と、モデルから得られた滞在時間分布の二乗平均平方根誤差 (RMSE) を、観測データの経験分布の二乗平均平方根で割ることで正規化した正規化二乗平均平方根誤差 (NRMSD) を用いた。この NRMSD が最も小さくなるモデルを最適モデルとして選定した。最終的なパラメータはこの最適モデルに対して、全データを用いて再度最尤推定法で推定した。

推定の結果、どの展示においても、最適モデルの NRMSD は、全混雑度・高混雑度どちらの場合でも、0.01~0.10 の範囲に収まった。このことから、提案モデルが実測データを良好に再現できることが示された。最適モデルのサービス時間分布と混雑度影響関数 $g(d)$ の内訳を図 4, 5 に示す。

全混雑度のフィッティングの結果を見ると、サービス時間分布としてはどの分布も一定数最適モデルとして選ばれていることがわかる。指数分布が最適モデルとして選ばれた展示では、滞在行動が単純であり、混雑度の影響も比較的小さいことが示唆される。Erlang 分布は複数個の指数分布から構成されるため、これが最適モデルとして選ばれた展示では、滞在行動が複数段階に分かれていることが示唆される。Weibull 分布は、他の分布よりも柔軟に分布形状を変化させられ、分布の裾野が広がる特徴がある。そのため、これが最適モデルとして選ばれた展示では、水族館特有の滞在行動やサービス時間のばらつきが色濃く出ていると考えられる。また、混雑度影響関数 $g(d)$ としては、線形減衰型と反比例型が最適モデルとして最も多く選ばれた。それに対して、シグモイド型は少なく、指数減衰型はほとんど選ばれなかった。このことから、混雑度によってサービス時間は、急には変化せず、比較的緩やかに変化することがわかる。

対して、高混雑度のフィッティングの結果を見ると、サービス時間分布としては Weibull 分布が最適モデルとして多く選ばれた。これは、高混雑度においては滞在行動がより複雑化し、Weibull 分布の柔軟性が有効に働いたためと考えられる。また、混雑度影響関数 $g(d)$ としては、変わらず線形減衰型が最も多く選ばれたが、次いでシグモイド型が多く選ばれた。これは、高混雑度の範囲内では、サービス時間が急激に変化することを示唆している。

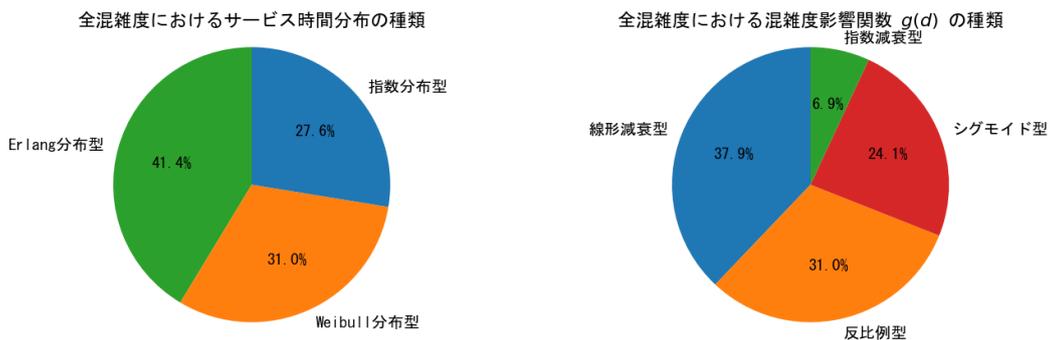


図 4: 全混雑度における最適モデルのサービス時間分布 (左) と混雑度影響関数 $g(d)$ (右)

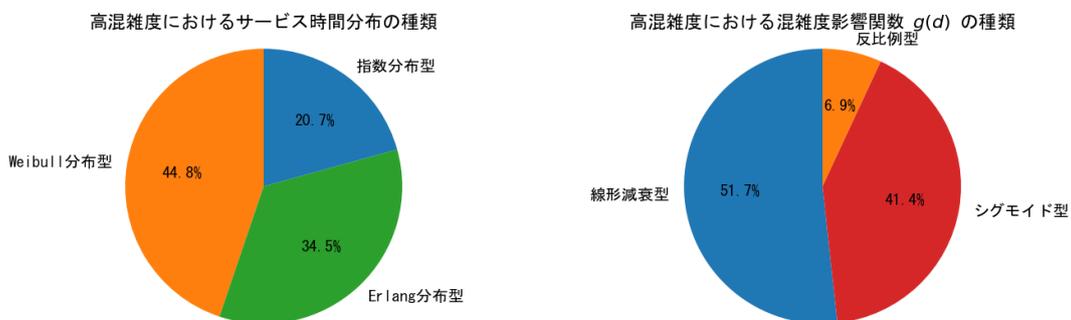


図 5: 高混雑度における最適モデルのサービス時間分布 (左) と混雑度影響関数 $g(d)$ (右)

ここで、新たに定義した「許容混雑度」と、推定した最適モデルのパラメータを元に、入口に最も近い展示1において、(6)を計算したところ、1分間に入場させるべき人数が、Kawaguchiら[2]が実際に提案した値と、海遊館で経験的に採用されている値と近い値になることが確認された。

ここまで、BLEセンサとビーコンから得られたデータを用いて、それぞれの展示に対して来館者の混雑度に応じたサービス時間分布を推定し、その妥当性を検証した。最後に、それぞれの展示について、実際に観測された「系内客数の時系列データ」と構築した最適モデルから、(5)を離散的に逆に解くことで、「入場者数の時系列データ」を推定した。これを最適モデルへの入力として、待ち行列シミュレーションを行った。これにより得られた系内客数過程のシミュレーションデータと実測データを比較することで、それぞれの展示に対しての提案モデルおよびシミュレータの妥当性を検証した。

そのシミュレーションの一例として展示1の結果を図6(左)に示す。このように、実測データと良好に一致していることが分かる。そして、このシミュレーションを全ての展示に対して実験期間の全日付で行った。その混雑度の平均絶対誤差の全日付での平均値のヒストグラムを図6(右)に示す。ほとんどの展示で誤差が0.10以内に収まっており、提案モデルおよびシミュレータの妥当性が確認された。

さらに、本研究では長期間にわたる観測データを用いてパラメータ推定を行っているため、突発的な混雑や一時的な外乱の影響を受けにくい、ロバストな推定が実現されていると考えられる。このため、コロナ禍のような社会的に大きな変動要因が生じない限り、例えば2024年のデータから推定したパラメータを、翌年以降の混雑状況予測やシミュレーションに適用することも十分に可能であると期待される。以上より、各展示に対して、その混雑度を再現できるだけでなく、将来的な運用や計画立案にも利用可能な汎用的シミュレータが構築できたことになる。

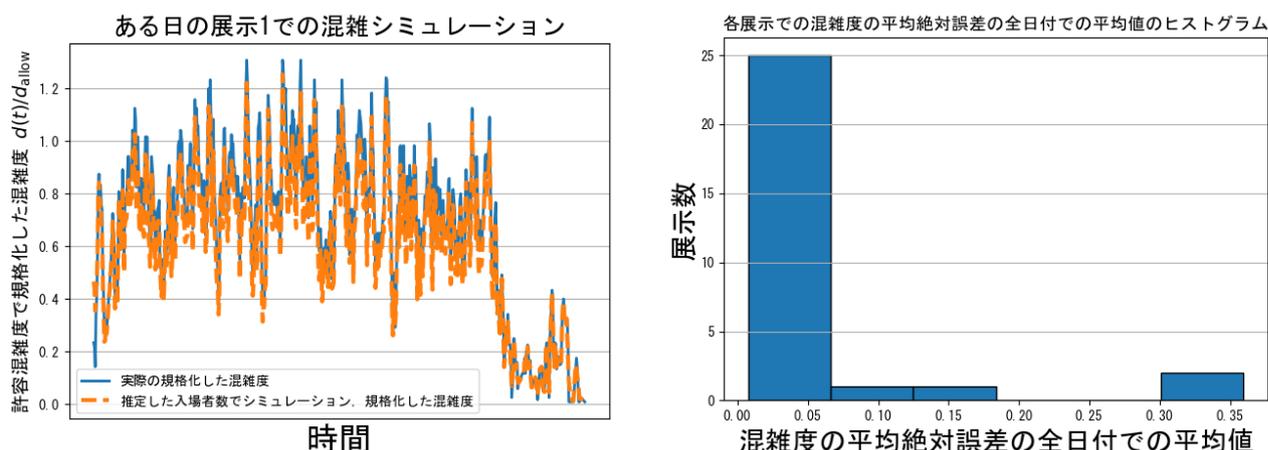


図 6: 展示1におけるある日の系内客数過程シミュレーション結果(左)と、各展示での混雑シミュレーション結果と実際の混雑度との平均絶対誤差の全日付での平均値のヒストグラム(右)

その一例として、このシミュレータを用いることで、総入場者数を実際と同じに保ちつつ、「許容混雑度」で規格化した混雑度が常に1以下となるような入場者数の時系列データを計算できる。具体的には、まず実測の系内客数の時系列と最適モデルから、(5)を離散的に逆に解くことで到着数の時系列 $\mathbf{a}^{(0)}$ を推定する。次に、最適モデルを用いて、 $\mathbf{a}^{(0)}$ を「総到着数 $\sum_t a_t$ を保存したまま」再配分し、期待混雑度が $d(t) \leq d_{allow}$ を満たす到着数の時系列 \mathbf{a}^* を求める。この再配分は逐次凸最適化により行う。各反復では $\|\mathbf{a} - \mathbf{a}^{(0)}\|$ を最小化しつつ、 $d(t) \leq d_{allow}$ を満たす凸二次計画問題を解くという手順を繰り返す。これにより、許容混雑度を超えない最適入場者数の時系列 \mathbf{a}^* を得る。得られた \mathbf{a}^* を入力として $M_t/G_d/\infty$ 待ち行列シミュレーションを行った一例として展示1の結果を図7に示す。このように、実際の入場者数の合計を保ちながら、許容混雑度を超えない、すなわち現状よりも快適な鑑賞環境を提供できる入場者数の時系列データを得ることができた。同様にして、このシミュレータを用いて、1日やその中の特定の時間帯において、目標の入場者数を設定し、その目標を達成しつつ許容混雑度を超えない入場者数の時系列データを得ることも可能である。

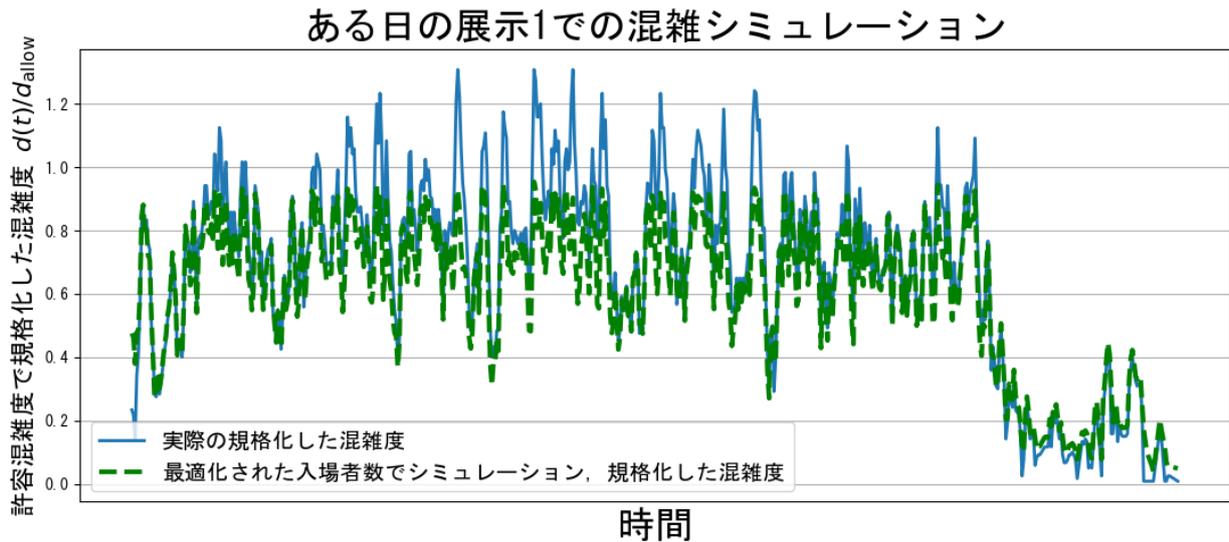


図 7: 展示 1 におけるある日の系内客数過程シミュレーション結果 (許容混雑度で規格化された混雑度が 1 を超えず、入館者数の合計が同じになるように調整した一例)

7. デジタルツイン構築のためのネットワークモデル

実際の観覧型展示施設では、来館者が複数の展示を巡回するため、ある展示での制御が他展示に影響を与え、結果として施設全体の混雑を悪化させる可能性がある。よって、各展示を独立に扱うのではなく、展示間の関係を考慮した統合的な混雑解析が必要不可欠である。

そのため、これまでに構築してきた状態依存サービス時間分布をもつ $M_t/G_d/\infty$ モデルを展示間で接続することにより、複数展示をまたぐデジタルツインを構築できることを示す。これにより、来館者の流れを展示単体から展示間へと拡張して扱うことが可能となる。

具体的には、各展示に対して入場者数の時系列を与えることで、前章で検証したシミュレータを用いて系内客数の推移を再現し、対応する退場者数の時系列を得る。次に、この退場者数の時系列に移動時間モデルを適用することで、次の展示における入場者数の時系列を生成する。この移動時間モデルは、退場する展示および到着先展示の混雑度に依存する移動時間分布として構築されている。

ただし、現在はセンサの設置数が限られており、設置されている展示 3 から展示 7 までの移動中に来館者がその間の展示を鑑賞している。そのため、推定された移動時間分布が純粋な移動時間を必ずしも正確に反映していない可能性がある。

以上の枠組みに基づき、本研究では展示 3 と展示 7 を接続したデジタルツインの一部を構築した。(図 8 参照)



図 8: 展示 3 から展示 7 までの接続イメージ

2025年9月17日以降、BLEセンサを用いて展示間の移動時間を計測する実験を開始しており、展示3から展示7までの移動時間分布を推定し、移動時間モデルを作成した。

展示3の実測された系内客数過程に対し、前章で構築したシミュレータを用いて退場者数の時系列を推定し、これに移動時間モデルを適用することで、展示7における入場者数の時系列を生成した。これを展示7のシミュレータに入力し、得られた系内客数過程を展示7の実測データと比較した結果を図9に示す。

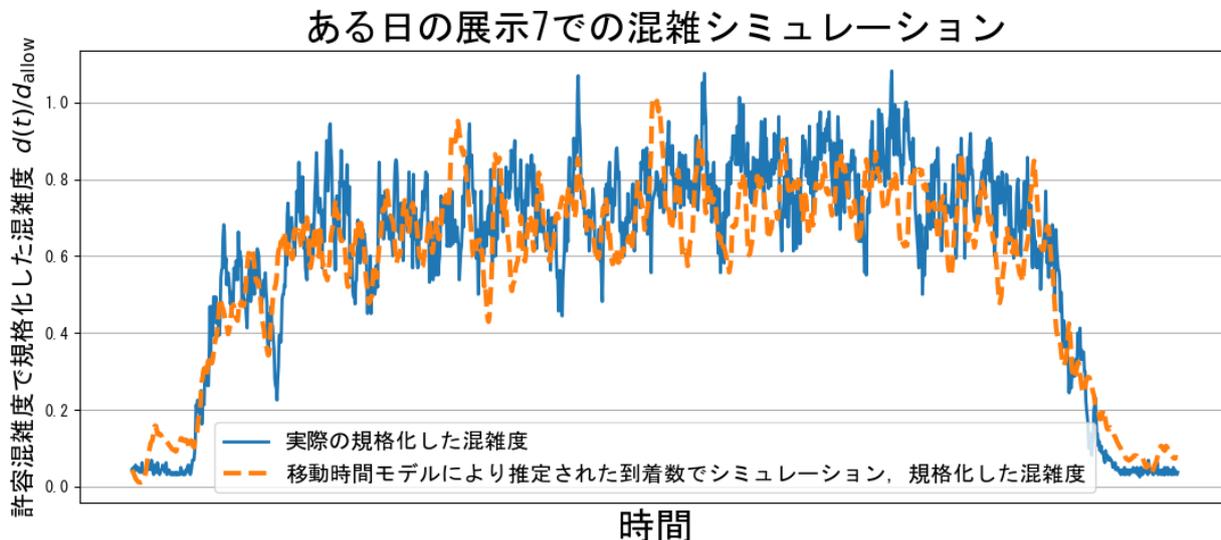


図9: 展示3の予想退場者数と移動時間モデルを元にした展示7でのある日の系内客数過程シミュレーション結果

図9より、展示7における系内客数過程の全体的な傾向は良好に再現できており、展示モデルを接続することで、展示間の来館者の移動を反映したシミュレーションが可能であることが確認できる。

今後、センサの設置数を増やし、展示間の移動時間データをより詳細に収集することで、移動時間モデルの精度向上が期待される。これにより、展示間の接続をさらに拡張し、施設全体を対象としたデジタルツイン構築へと発展させることが可能となる。

この際、海遊館では回遊ルートが一方通行であるため、展示間の遷移行列を導入する必要はなく、ある展示の退場者数そのまま次の展示の入場者数となる。この特性を活かし、入口から出口まで順に展示モデルを接続することで、施設全体の混雑状態を再現する枠組みを構築できる。この際、デジタルツインモデルへの入力となる最初の入場者数の時系列は、施設の構造上、入口での入場者数の時系列に対応する。これは実際の運用において唯一明示的に取得・制御が可能なデータであり、デジタルツインの入力として適している。これにより、混雑最適化のためのサービス関数設計や人員配置、サービス時間調整などを検討できるほか、トラブル発生時の影響やその波及、対応策をリアルタイムに評価することが可能となる。

8. 結論と今後の展望

本研究では、観覧型展示施設における混雑現象を統一的に扱うため、状態依存サービス時間分布を持つ $M_t/G_d/\infty$ モデルを提案し、展示単体から施設全体まで拡張可能な混雑解析枠組みを構築した。

理論面では、基礎方程式の導出を示し、一般分布を12種類に分類した際の制御設計指標を明らかにした。実証面では、BLEセンサデータを用いて提案モデルの再現性と相補性を確認し、海遊館でのケーススタディにより制御指標となる混雑度の定義を提示し、混雑状況の高精度な再現と具体的な制御策への応用可能性を示した。さらに、各展示モデルを接続することで施設全体のデジタルツイン構築の枠組みを提示し、施設全体の混雑解析と制御へと発展できることを示した。

一方で、展示間の移動時間モデルやサービス時間モデルには依然として改良の余地が残されている。今後は、移動時間データの収集と詳細なモデリングを進めつつ、時間帯や館内イベント、季節要因な

ど複数の要因をサービス時間モデルに取り込むことで、より現実的かつ精緻なモデルへ発展させる必要がある。また、BLE センサの特性に依存して決まる各種パラメータに対しては、センサの改良やキャリブレーション手法の確立を通じて精度向上を図ることが重要である。さらに、チケット発券枚数などの入館条件をモデル化し、デジタルツインを用いてその最適化を検討するとともに、海遊館以外の施設へ適用することで、本研究で提案した混雑解析手法の一般性と実用性を検証していくことが今後の課題である。

9. 謝辞

本研究を進めるにあたって、株式会社海遊館と株式会社グッドフェローズの皆様には多大なるご支援とご協力を賜りました。この場を借りて深く感謝申し上げます。

また、本研究は、JSPS 科研費 JP25K17790, JP23K21019, JP23K13521 の助成を受けたものです。

参考文献

- [1] Sifeng Nian et al., Tourist Crowding versus Service Quality: Impacting Mechanism of Tourist Satisfaction in World Natural Heritage Sites from the Mountain Sanqingshan National Park, China, *Sustainability*, **16** No.18, (2024), 8268.
- [2] Riho Kawaguchi et al., Two Types of Bottlenecks in Leisure Facilities: Bottlenecks Caused by Attractiveness and Structural Layout, *Physica A*, (2024), 101–108.
- [3] S.G.Eick et al., The Physics of the $M_t/G/\infty$ Queue, *Operations Research*, **41** No.4 (1993), 731–742.
- [4] S.G.Eick et al., $M_t/G/\infty$ Queues with Sinusoidal arrival rates, *Management Science*, **39** (1993), 241–252.
- [5] Peter W.Glynn and Ward Whitt, A New View of the Heavy-Traffic Limit Theorem for Infinite-Server Queues, *Advances in Applied Probability*, **23** No.1 (1991), 188–209.
- [6] Wenwei Li and A.Goldenshluger, Adaptive minimax estimation of service time distribution in the $M_t/G/\infty$ queue from departure data, *Queueing Systems*, **108** No.1–2, (2024), 81–123.
- [7] A.Goldenshluger and D.T.Koops, Nonparametric Estimation of Service Time Characteristics in Infinite-Server Queues with Nonstationary Poisson Input, *Stochastic Systems*, **9** No.3 (2019), 183–207.
- [8] Jamol Pender, Risk Measures and Their Application to Staffing Nonstationary Service Systems, *European Journal of Operational Research*, **254** No.1 (2016), 113–126.
- [9] Winner et al., Inference in a Partially Observed Queuing Model with Applications in Ecology, *Proceedings of the 32nd International Conference on Machine Learning*, **37** (2015), 2512–2520.
- [10] Pietro Centorrino et al., Managing Crowded Museums: Visitors Flow Measurement, Analysis, Modeling, and Optimization, *Journal of Computational Science*, **53** (2021), 101357.
- [11] Onofri et al., RSSi-Based Visitor Tracking in Museums via Cascaded AI Classifiers and Coloured Graph Representations, *Collective Dynamics*, **6** (2022), 1–17.
- [12] Kaiyukan. <https://www.kaiyukan.com/>.
- [13] 牧野 都治, 待ち行列論におけるアーラン分布とワイブル分布, *応用統計学*, **11** No.3 (1982), 153–158.
- [14] Y. Yoshimura et al., Noninvasive Bluetooth Monitoring of Visitors' Length of Stay at the Louvre, *IEEE Pervasive Computing*, **16** No.2 (2017), 26–34.
- [15] Riho Kawaguchi, Modeling and Real Data Analysis on Quasi-one-dimensional Systems with Bottlenecks: A Case Study in an Overcrowded Large-scale Aquarium, (ボトルネックがある準一次元流システムのモデリングと実データ解析: 混雑した大規模水族館を事例として), 東京大学工学系研究科 博士論文, (2023).