

# IoT プラットフォーム (EdgeX Foundry) を用いた 時系列データ解析と機械学習系のコンテナ構成

## Containerized Architecture for Time Series Data Analysis and Machine Learning Using EdgeX Foundry IoT Platform

増山 維央† 和崎 克己‡  
Io Masuyama Katsumi Wasaki

### 1 はじめに

近年, IoT (Internet of Things) の普及により, さまざまな分野でセンサーデータを活用したリアルタイム処理と高度な解析の重要性が増している. 特にスマートシティやスマートホーム, 環境モニタリングの分野では, センシングと情報処理を一体化したシステムが求められており, 例えば, 室内温度の急激な低下に応じて暖房を自動起動する仕組みは, 快適性の向上や高齢者支援にも資する. こうした仕組みを実現するには, データの収集・保存・解析を統合的に管理可能なプラットフォームが必要である. 本研究では, 東京都と長野県信濃町という異なる気候条件下における気象庁のオープンデータを EdgeX Foundry を介して取り込み, それに基づく時系列予測モデルの適用と予測精度の比較を行った. また, 機械学習モデルを組み込んだ予測パイプラインをコンテナ化し, 汎用的な構成として再利用可能なアーキテクチャを提案する.

### 2 時系列予測モデルとパラメータ選定

地域ごとに取得されたセンサーデータに対して時系列解析を行うため, ARIMA (自己回帰和分移動平均) および SARIMA (季節性自己回帰和分移動平均) モデルを採用した. SARIMA は, ARIMA モデルに季節成分を加えたものであり, 周期性を含む実世界の時系列データに適している. 特に, 寒冷地に見られる日較差や周期性のある変動を扱う上で有効である. モデル構造は  $SARIMA(p, d, q)(P, D, Q)[m]$  で表され, ここで  $(p, d, q)$  は自己回帰・差分・移動平均の次数,  $(P, D, Q)$  は季節成分の次数,  $m$  は季節周期である. パラメータは赤池情報量規準 (AIC) を基準として自動選定を行った. AIC はモデルの当てはまりと自由度のバランスを評価する情報量基準であり, 値が小さいほど予測精度が高いとされる. 具体的には,  $p, d, q, P, D, Q$  すべての構成に対して並列探索を行い, AIC が最小となるものを最適モデルとした. この手法により, 地域や期間ごとに異なるデータ特性に対して, 人的なチューニングを要せずに適応可能なモデル構築を実現した.

### 3 予測システムの実装構成

本研究では, IoT デバイスから収集されたデータを効率的に管理・解析するために, EdgeX Foundry を中心

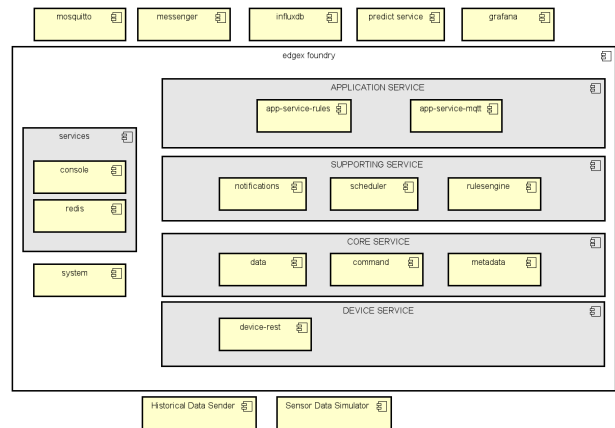


図1 EdgeX プラットフォームの内部構成図

に構築されたデータ解析システムを設計した. このシステムは, データ収集, 保存, 可視化, さらに時系列解析を統合したものであり, 図1に全体構成を示す. 本研究で構築した IoT データ解析システムは, EdgeX Foundry を基盤として設計されており, データの収集, 処理, 保存, 可視化, 予測を一連の流れで実現する. 図3に示すように, このシステムは複数のモジュールとサービスで構成されており, それぞれが特定の役割を担っている. 過去に収集されたデータは Historical Data Sender を通じて EdgeX Foundry に送信される. このモジュールは, 過去データを再利用し, 予測モデルの検証や過去データを用いた再解析を可能にする. 過去データの活用は, モデルの精度向上や動作確認において重要な役割を果たす. センサーデータは, Sensor Data Simulator で生成される. このモジュールは, 仮想センサーとして機能し, リアルタイムでデータを生成する. 生成されたデータは, EdgeX Foundry の Device Service 層に送信され, システム全体で扱いやすい形式 (主に JSON 形式) に変換される. これにより, 実際の物理センサーを使用せずに, システム全体の動作を検証することができる.

### 4 地域別気温予測の実験と評価

本研究では, 東京都および長野県信濃町における気象庁のオープンデータを用いて, SARIMA モデルによる気温予測を行い, 地域ごとの予測精度を比較した. 各地域について, 24 時間の観測データに基づいて 24 時間先の気温を予測し, 予測結果と実測値を比較することでモデルの適応性を評価した. 図2は東京都における予測結果である. 本データは 2024 年 5 月上旬の観測データをもとに, 24 時間先までを SARIMA モデルで予測

† 信州大学大学院総合理工学研究科, Graduate School of Science and Technology, Shinshu University

‡ 信州大学工学部電子情報システム工学科, Department of Electrical and Computer Engineering, Faculty of Engineering, Shinshu University




図2 東京都における気温予測結果 (SARIMA モデル)




図3 信濃町における気温予測結果 (SARIMA モデル)

したものである。都市部では日内変動が比較的穏やかであり、モデルは実測値に対して滑らかに追従している。ピークや谷の時刻も概ね一致しており、予測性能としては良好であった。このときの誤差評価として、平均絶対誤差 (MAE: Mean Absolute Error) は約  $1.08\text{ }^{\circ}\text{C}$ 、二乗平均平方根誤差 (RMSE: Root Mean Square Error) は約  $1.26\text{ }^{\circ}\text{C}$  であり、予測のばらつきも小さい結果となった。次に、図3は信濃町における2024年1月中旬の予測結果である。信濃町は寒冷地であり、特に冬季には深夜から早朝にかけて急激な冷え込みが発生する。図からも分かるように、モデルは全体的な傾向には追従しているが、気温が急変する局面において予測誤差が拡大しており、特に深夜帯ではモデルが過小評価する傾向が確認された。この期間におけるMAEは約  $1.80\text{ }^{\circ}\text{C}$ 、RMSEは約  $2.16\text{ }^{\circ}\text{C}$  であり、東京都の予測と比較して誤差が大きくなっていることが分かる。

これらの結果から、SARIMAモデルは周期性が比較的一定で日内変動の小さい都市部においては高い予測精度を発揮するが、気候の変動が激しい寒冷地においては急激な変化を正確に捉えきれない傾向があることが分かる。また、RMSEは外れ値の影響を強く受けるため、実測値と予測値に大きな差が生じた場合にモデルの限界が顕著に現れる指標として機能する。一方、MAEは平均的な誤差を捉えるため、日常的な運用における予測の「ずれ感」を定量的に把握する際に有効である。本研究では、この2つの指標を併用することで、モデルの適応状況とその制限をより明確に評価することができた。

## 5 コンテナ構成の設計

本研究で構築した予測パイプラインは、Docker Composeを用いて管理される複数のコンテナサービスによって構成されている。主な処理は、Preprocessor (前処理)、Predictor (予測)、Postprocessor (後処理) の3段階からなり、それぞれの処理は独立したコンテナとして実装されている。これにより、処理の分離と保守性の向上、モデル切替時の柔軟な再構成が可能となる。さらに、本システムでは予測モデルの自動最適化を実現するため、Auto-Tuning Engine (ATE)を導入した。Predictorは、ARIMAやSARIMAなど複数の時系列モデルを一つのコンテナ内で切り替えられる構成とし、ATEは、Postprocessorから得られる予測精度の評価指標 (RMSE, MAE など) と、入力系列に含まれる周期性

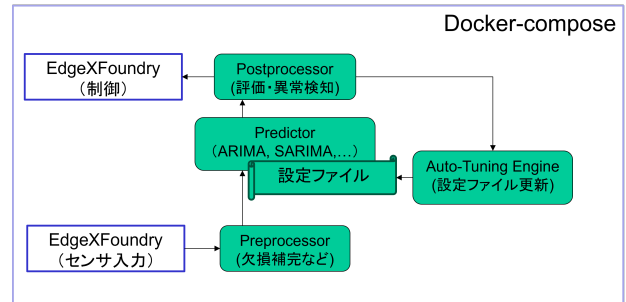


図4 コンテナ構成図

の情報に基づき、モデル構成ファイル (model\_config.yaml) を動的に更新する。更新後はPredictorがその変更内容を自動的に反映し、モデルの再学習またはアルゴリズムの切替を行う。また、ATEを含めた各サービスの定義はDocker Composeで記述されており、全体構成の再現性と移植性を担保している。この構成により、現場環境やセンサーデータの変化に応じて自律的に再学習・構成変更が可能となる柔軟な予測システムが実現できると期待される。今後の実装および運用試験を通じて、その有効性を確認していく予定である。

## 6 まとめと今後の課題

本研究では、IoT環境におけるセンサーデータ活用の高度化を目的とし、ARIMAおよびSARIMAモデルの適用と、AICに基づくパラメータ自動選定により、人的調整を排した予測モデル構築を行った。また、EdgeX Foundryによるデータ基盤と、Preprocessor, Predictor, Postprocessorからなるコンテナ型予測パイプラインを設計し、柔軟な構成変更を可能にするAuto-Tuning Engine (ATE)を組み込んだ。東京都と信濃町の気温予測実験では、都市部に比べて寒冷地では気温変化が急激であり、SARIMAモデルによる予測誤差の増大が確認された。これにより、環境特性に応じた構成調整の必要性が示唆された。本構成は、Docker Composeによる高い再現性と移植性を備えつつ、再学習やモデル切替を自律的に実行可能な設計となっており、実運用を見据えた柔軟な予測基盤として有効であると考えられる。今後は、より複雑な環境下での動作検証に加え、評価指標の多様化 (例: MAPEや異常スコアの導入)、学習済みモデルの管理・蓄積手法の整備が求められる。さらに、EdgeX Foundryとの連携を一層強化し、予測結果や評価指標をEdgeX内部のルールエンジンと接続することで、自動制御系への応用を実現していく方針である。特に、外れ値の検出結果に基づき、リアルタイムでアラートや制御命令を発信できる構成の実装が重要となる。これにより、スマートな現場対応や異常時の迅速な制御が可能となり、IoTプラットフォーム全体としての実用性と価値の向上が期待される。

### 参考文献

- [1] 島田直希: 時系列解析, 共立出版, 2019
- [2] 気象庁: 気象データ, <https://www.jma.go.jp/jma/index.html>
- [3] EdgeX Foundry: <https://www.edgex.org/>
- [4] Jonas Werner: EdgeX-Foundry-tutorial-ver1.0, <https://docs.edgexfoundry.org, 2020>
- [5] Grafana: <https://grafana.com/>