

機械学習・数値シミュレーション技術の融合による風況・塩分粒子解析の効率化

コンクリート研究室 恩田樹安
指導教員 中村文則

1. はじめに

沿岸部に設置されたコンクリート構造物では、海域から発生する飛来塩分が、コンクリート内部の鋼材の腐食を引き起こす要因の一つとなるため問題となっている。その対策として、コンクリート構造物に作用する飛来塩分を予測する研究が進められている。例えば、豊田ら¹⁾、中村ら²⁾は、風と飛来塩分粒子を統合した数値解析を実施し、構造物形状を考慮したコンクリート表面への飛来塩分の到達量の予測を行っている。これらの研究成果により、構造物形状や周辺地形を考慮して、風や飛来塩分を3次元空間で予測できるようになっている。

しかしながら、既往研究で開発されている高度な数値シミュレーションでは、風や飛来塩分量を正確に予測できるが、膨大な計算時間が必要であるといった欠点がある。特に、コンクリート構造物の劣化は、長期間かつ時系列的に変化する自然環境作用が原因となるため、環境条件を変化させた膨大なパターンの解析が必要となる。中村らの既往研究³⁾では、実構造物に作用する長期間の飛来塩分を予測するために、1000 ケース程度の風・飛来塩分の予測解析を実施している。その一方で、Peng ら⁴⁾は、機械学習を利用して数値解析を効率的に実施する方法を報告している。このような機械学習による方法を風況や飛来塩分の塩害環境予測解析に利用することができれば、構造物の塩害劣化を効率的に予測できる可能性がある。




図-2 計算の対象とした風洞実験施設

本研究では、コンクリート構造物の塩害環境予測解析を効率的に実施できるようにするために、風況の数値シミュレーションに機械学習を援用した予測方法について検討を行った。さらに、機械学習モデルを用いて橋桁に作用する風向の違いを考慮した予測解析を実施し、その塩害環境予測への適用性について考察を行った。

2. 塩害環境予測解析(風・飛来塩分解析)の方法

2.1 塩害環境予測解析の全体構成

図-1 は、予測解析の計算全体の流れを示したものである。図に示すように、本計算は、機械学習モデルで風の場の計算を行い、その結果を利用して飛来塩分の数値シミュレーションを実施する流れである。機械学習モデルの教師(学習)データには、風の場の3次元数値シミュレーションの計算結果を利用した。数値シミュレーションと機械学習モデルは、次のようなものを使用した。

2.2 数値シミュレーションモデル

(1) 風の場の数値シミュレーション

コンクリート橋桁周辺の風の場のシミュレーションには、OpenFOAM を使用した。OpenFOAM は、オープンソースのソフトウェアであり、数値流体力学の分野で幅広く利用されている。特に3次元の風の場の解析において多くの実績がある。支配方程式の解法は有限体積法であり、構造物の形状を正確に再現できる特徴がある。構造物周辺の風の場の計算には、非圧縮性流体と仮定した3次元の $N-S$ 方程式モデルを用いた。

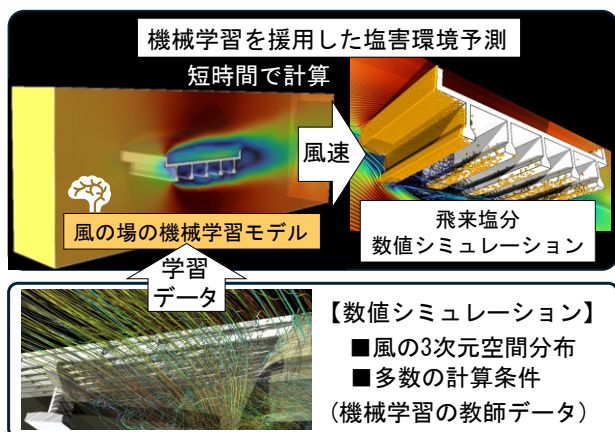


図-1 塩害環境予測解析の計算全体の流れ

(2) 飛来塩分の数値シミュレーション

風の場合に応じた飛来塩分粒子の移動・到達過程の予測は、中村らの既往研究²⁾を参考に粒子追跡法による解析モデルを構築して行った。本手法は、飛来塩分粒子を球体と仮定し、その球体に作用する風の抵抗力と粒子の自重による慣性力のつり合いから、飛来塩分の移動および到達過程を計算するものである。構造物表面への粒子の到達は、計算時間ステップの前後で、大気中の粒子の位置が表面部を接触した場合に到達すると判定した。

2.3 風場の予測に援用した機械学習モデル

(1) 機械学習モデル

機械学習モデルは、Li^ら⁵⁾が考案したFNO(Fourier Neural Operator)である。このモデルは、教師(学習)データと出力データとの関係から演算子を直接学習することで予測解析を行う方法である。空間全体で風速や圧力分布などの数値シミュレーションの計算結果を学習し、予測解析を行う点に特徴がある。教師データの学習は、高速フーリエ変換(FFT)に基づく演算方法である。予測計算および教師データの学習は、等間隔の直交格子状に配置された空間で実施される。

(2) 学習に利用する教師データ

機械学習モデルの学習のための教師データには、橋桁周辺における風場の3次元数値シミュレーションの計算結果を使用した。OpenFOAMによる数値シミュレーションは、計算格子が不等間隔の非構造形式である。一方で、機械学習モデル(FNO)では等間隔の直交格子で学習および予測を行っている。そのため、教師データは、数値シミュレーションの計算結果を機械学習の計算格子に一致するように再配置する方法で構築した。

3. 橋桁形状に対する機械学習の適用性の検討

3.1 対象とするコンクリート橋桁

コンクリート橋桁を対象とした風場の予測に機械学習を援用した予測計算を実施し、その適用性について検討を行った。計算は、橋桁近傍の風場を詳細に確認するため、長岡技術科学大学に設置されている図-2のような風洞実験施設を再現した領域で実施した。風洞実験施設の寸法(風が流れる範囲)は、長さ5500mm、幅900mm、高さ2000mmである。対象とした橋桁模型はT桁形状である。模型は、風洞実験施設内の風上側の境界から1700mmの位置に設置されている。

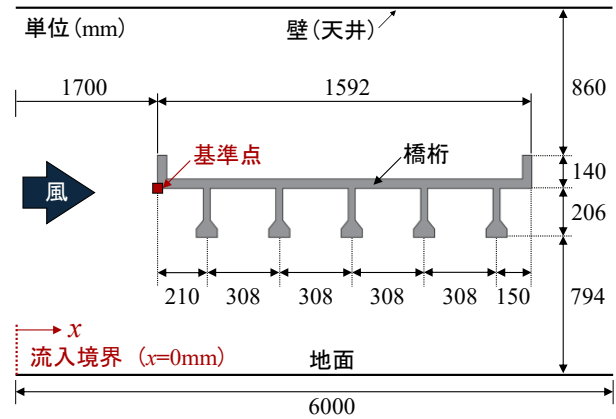


図-3 計算領域と対象橋桁形状

表-1 機械学習モデルの構築条件

| カテゴリー | ハイパーパラメータ |
|--------|---------------------------------|
| モデル | 内部チャンネル幅 : 48 |
| | ネットワーク深さ : 4 |
| | フーリエモード数 : [x= 36, y=16, z= 24] |
| データセット | 空間解像度 : [x=256, y=64, z=128] |
| | 入出力チャンネル数 : 入力(7) / 出力(3) |
| 学習プロセス | 学習エポック数 : 100 |
| | バッチサイズ : 2 |
| | 学習率 : 0.001 |
| | オプティマイザ : AdamW |
| | 活性化関数 : GELU |

3.2 機械学習モデルと教師データの構築方法

(1) 機械学習モデルの計算領域と教師データ

風場の計算領域は、図-3のような長さ6000mm、幅900mm、高さ2000mmの3次元の空間である。橋桁の寸法は、長さ1592mm、幅900mm、高さ346mmである。橋桁の寸法は、風上側の境界面から長さ1700mm、高さ1000mmの位置に設置されている。計算格子数は長さ方向256個、幅方向64個、高さ方向128個である。機械学習モデルの内部チャンネル幅は48、ネットワーク深さは4とした。フーリエモード数は、モデル内部で扱う低周波数成分を規定するパラメータであり、長さ方向36、幅方向16、高さ方向24に設定した。

機械学習モデルの学習に用いた教師データの入力項目(チャンネル数)は、構造物の存在を表す符号付き距離関数および風速のスカラー量、風向のx成分とy成分、3次元空間座標の合計7項目である。出力項目(チャンネル数)は、領域全体の3成分の風速とした。機械学習では、入力項目と出力項目のパターンを学習し、任意の流入風速を与えた際に3次元の流れ場を予測する。機械学習モデルの構築に用いた学習条件を表-1に整理した。

表-2 風の場の数値シミュレーションの条件

| 項目 | 設定値 |
|--------|-------------------------------------|
| 流入境界 | 風速 1~30m/s (1m/s間隔) |
| | 風向 1方向(橋桁直交方向) |
| 流出境界 | 自由流入出境界 |
| 乱流モデル | 非定常流 |
| | LES (Smagorinskyモデル) |
| 計算時間 | 60秒 |
| 計算格子 | 基本格子数 : 537334 |
| | 最大格子幅 : 53mm |
| | 最小格子幅 : 6mm |
| テストデータ | 風速 4, 8, 15, 28m/s (学習に含めない4データ) |

(2) 教師データの構築方法

機械学習の教師データを構築するために、風の場の数値シミュレーションを実施した。数値シミュレーションの計算条件を表-2に示す。風洞実験施設と橋桁模型を再現した条件で3次元の風の場の計算を実施し、その結果を教師データとした。風の流れの1回の計算時間は60秒間である。非定常の渦の影響を平均化するために、計算開始後30~60秒間の風速分布を平均化した。その後、機械学習の計算格子に一致するように、計算結果の再分配を行った。教師データの構築のための計算ケースは、風速を1~30m/sまでの範囲を1m/s間隔で計算し、機械学習による予測結果の精度の確認に利用する4ケース(テストデータ)を除外した26ケースである。

(3) 機械学習モデルへの教師データの学習方法

学習に用いた26ケースの数値シミュレーションの計算結果は、訓練データと検証データの比率が7:3となるように設定した。機械学習モデルへの教師データの学習では、モデルを最適化(損失関数を最小化)させるために、訓練データを用いたパラメータの更新と検証データを用いた精度検証を反復する方法で学習を行った。

さらに、機械学習モデルの予測精度を向上させるために、損失関数は平均二乗誤差(MSE)および相対L²誤差、相対H¹誤差を用いて3種類のモデルを構築し、最適な損失関数について検討を行った。1つ目の損失関数は、各格子点における予測値(機械学習)と正解値(数値シミュレーション)の差の二乗を空間全体で平均化した平均二乗誤差(MSE)であり、式(1)で算出した。

$$MSE = \frac{1}{|\Omega|} \sum_{i \in \Omega} (\hat{u}_i - u_i)^2 \quad (1)$$




図-4 機械学習モデルの予測結果の相対誤差率

ここで、 \hat{u}_i は各格子点*i*におけるFNOの予測値、 u_i は教師データの正解値、 Ω は計算領域を離散化した際の格子点の集合、 $|\Omega|$ はその総数である。

2つ目は、予測値と正解値の差のL²ノルムを正解値のL²ノルムで正規化した相対L²誤差であり、式(2)で算出した。

$$Rel L^2 = \sqrt{\frac{\sum_{i \in \Omega} (\hat{u}_i - u_i)^2}{\sum_{i \in \Omega} u_i^2}} \quad (2)$$

3つ目は、L²ノルムに加えて空間勾配の誤差を考慮した指標である相対H¹誤差である。この誤差は、機械学習モデルが出力する解の滑らかさや空間的な変化特性を直接考慮できる特徴があり、式(3)で算出した。


$$Rel H^1 = \sqrt{\frac{\|\hat{u} - u\|_{L^2(\Omega)}^2 + \|\nabla \hat{u} - \nabla u\|_{L^2(\Omega)}^2}{\|u\|_{L^2(\Omega)}^2 + \|\nabla u\|_{L^2(\Omega)}^2}} \quad (3)$$

ここで、 ∇ は空間勾配演算子である。

3.3 機械学習モデルによる予測結果および考察

(1) 損失関数と風速の違いによる予測精度

構築した機械学習モデルの予測結果について予測精度の確認を行った。対象ケースは、損失関数3種類と風速条件を変化させた4ケースの合計12ケースである。風速条件は、4m/s, 8m/s, 15m/s, 28m/s(テストデータ)の機械学習モデルで学習を行っていない風速である。予測精度の評価は、機械学習モデルと数値シミュレーションの予測結果から算出した計算領域全体の相対誤差率の値を用いた。図-4は、機械学習モデルの予測結果の相対誤差率を整理した結果である。図に示すように、誤差率が最も低い値を示したのは、学習時の損失関数に相対H¹誤差を用いたモデルであり、



(a) 機械学習モデル

(a) 数値シミュレーション

(c) 風速の差

図-5 風の場の予測結果

相対誤差は 6%前後である。空間の風速の勾配情報を学習時の損失計算に考慮することで誤差率が低減したと考えられる。

(2) 機械学習モデルによる風の場の予測結果

図-5 は、機械学習モデルと数値シミュレーションの風の場の予測結果を示したものである。図の機械学習モデルの損失関数は相対 H^1 誤差、風速の条件は機械学習モデルで学習を行っていない風速 4m/s である。図(a)に示すように、機械学習による予測で領域全体の風の流れと橋桁下部の主桁間のできる渦状の流れを予測できていることが分かる。図(b)は、数値シミュレーションの計算結果であるが、機械学習モデルによる予測結果と風の場の傾向がほとんど一致している。


図(c)は機械学習モデルの予測と数値シミュレーションによる計算の風速の差を示したものである。図では、橋桁下部の一部の部分で風速の差が大きくなっているが、その他の箇所では風速の差が 1m/s 以下となっている。風速の差が大きくなっている部分は、局所的に風速が大きく変化している部分である。これは、機械学習モデル(FNO)による方法では、空間全体の計算結果から風速を予測するため、局所的な風速の変化を正確に予測することが難しく、両者の予測結果に差が生じたと考えられる。

また、機械学習モデルを用いた 1 回の予測時間は、10 秒程度であり、機械学習モデルを一度構築することで効率的に風の場の予測ができることが確認された。


3.4 橋桁に作用する飛来塩分粒子の予測結果

(1) 飛来塩分粒子の計算条件

機械学習の風の場の予測結果を利用して、飛来



(a) 機械学習モデルの風況を用いた結果



(b) 数値シミュレーションの風況を用いた結果

図-6 飛来塩分粒子の計算結果

塩分粒子の予測計算を実施した。風の場合には、損失関数に相対 H^1 誤差、風速 4m/s の計算結果を用いた。飛来塩分粒子の計算条件は、粒子の粒径が直径 $25\mu\text{m}$ 、抵抗係数が 0.44、空気の密度が 1.23kg/m^3 、粒子の密度が 1000kg/m^3 である。橋桁模型の風上側に粒子を配置し、構造物に 150000 個の粒子が到達するまで計算を実施した。

(2) 飛来塩分粒子の計算結果および考察

図-6 は、機械学習と数値シミュレーションの風の場の計算結果を使用して飛来塩分粒子を計算した結果である。図に示すように、橋桁に到達した飛来塩分粒子の分布は、両者で概ね一致して

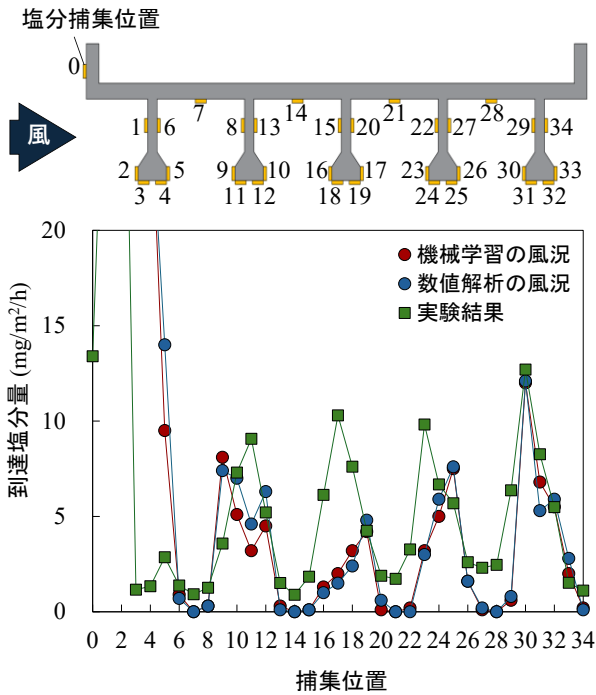


図-7 飛来塩分粒子の到達量

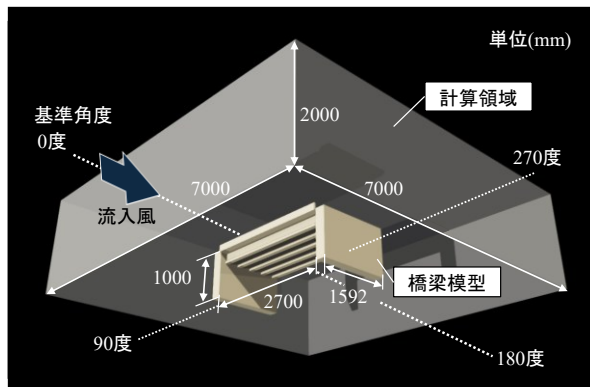


図-8 風向を考慮した計算領域

いる傾向が見られる。この結果から、機械学習モデルによって予測された風の間場を利用した方法でも、飛来塩分粒子の挙動を再現できることが明らかになった。

図-7は、橋桁模型に対して飛来塩分粒子の到達量を示したものである。横軸は上図に示す塩分粒子の捕集位置である。縦軸は、塩分粒子1個を $0.1\text{mg/m}^2/\text{h}$ としたときの塩化物イオン量である。図の実験結果は、流入風速 4m/s で実施された風洞実験の塩分到達量の結果である。

実験結果の塩化物イオン量は、模型表面に観測したガーゼのプレートを設置し、各位置の到達塩分量を測定した結果である。図より、機械学習と数値シミュレーションの風の間場を用いた結果は、

表-3 機械学習モデルの構築条件

| カテゴリ | ハイパーパラメータ |
|--------|---------------------------------|
| モデル | 内部チャンネル幅 : 32 |
| | ネットワーク深さ : 4 |
| | フーリエモード数 : $[x=32, y=32, z=16]$ |
| データセット | 空間解像度 : $[x=256, y=256, z=64]$ |
| | 入出力チャンネル数 : 入力(7) / 出力(3) |
| 学習プロセス | 学習エポック数 : 300 |
| | バッチサイズ : 1 |
| | 学習率 : 0.001 |
| | オプティマイザ : AdamW |
| | 活性化関数 : GELU |

表-4 風の間場の数値シミュレーションの条件

| 項目 | 設定値 |
|--------|-------------------------------------------------------------|
| 流入境界 | 風速 $1\sim 10\text{m/s}$ (1m/s 間隔) |
| | 風向 16方位 (22.5° 間隔) |
| 流出境界 | 自由流入流出境界 |
| 乱流モデル | 非定常流 |
| | LES (Smagorinskyモデル) |
| 計算時間 | 60秒 |
| 計算格子 | 基本格子数 : 543640 |
| | 最大格子幅 : 240mm |
| | 最小格子幅 : 30mm |
| テストデータ | 風向 $22.5^\circ, 157.5^\circ, 247.5^\circ$ (学習に含めない30データ) |

橋桁の中央主桁部のNo.16~18で実験結果と差が生じているが、全体的な分布の変動傾向は概ね一致する結果である。

4. 風向を考慮した機械学習モデルの構築


4.1 機械学習モデルの構築方法

風速および風向が同時に変化する場合の機械学習モデルの汎化性能について検討を行った。図-8に計算領域を示す。計算領域の寸法は、長さ 7000mm 、幅 7000mm 、高さ 2000mm である。橋桁部の寸法は、長さ 1592mm 、幅 2700mm 、高さ 346mm である。橋桁の両側端部には長さ 1592mm 、幅 200mm 、高さ 1000mm の壁を設置した。


機械学習モデルの構築に用いた学習条件を表-3に示す。学習時の損失関数には相対 H^1 誤差を採用した。

4.2 教師(学習)データの構築方法

教師データの構築は、風の間場の数値シミュレーションの計算結果から構築を行った。数値シミュレーションの計算条件を表-4に示す。解析データ数は、各16方位に対して、風速を $1\sim 10\text{m/s}$ までの範囲を 1m/s 間隔で計算した合計160ケースである。機械学習モデルの予測結果の検証に利用




(a) 機械学習モデルの風況を用いた結果




(b) 数値シミュレーションの風況を用いた結果

図-9 飛来塩分粒子の計算結果
(風向 247.5 度・風速 5m/s)



(a) 機械学習モデル



(b) 数値シミュレーション

図-10 風向を考慮した風の場の比較
(風向 247.5 度・風速 5m/s)

するための風速条件のデータ(テストデータ)の 30 ケースを除外し、最終的に 130 ケースを教師データとした。学習に用いたケースは、訓練データと検証データの比率が 7:3 となるように設定した。

4.3 飛来塩分粒子の予測結果および考察

図-9 に飛来塩分粒子の輸送・到達過程の計算結果を示す。風の場合に用いた条件は、機械学習モデルで学習を行っていない風向 247.5 度、風速 5m/s の条件である。飛来塩分粒子の計算は、風洞施設を再現した計算と同様の条件である。図に示すように、機械学習モデルの風の場合に用いた飛来塩分粒子の到達状況は、橋桁の風下側に分布している傾向が見られる。機械学習と数値シミュレーションの結果を比較した場合は、前者の方が飛来塩分粒子の到達する範囲が広く分布していることが分かる。これは、機械学習モデルと数値シミュレーションのそれぞれで予測した風の場合、局所的に異なるためであると考えられる。

飛来塩分粒子の計算に用いた機械学習モデルと数値シミュレーションの風の場合の計算結果を図-10 に示す。図に示すように、機械学習モデルで学習を行っていない風速の条件であるが、壁や

橋桁端部で流れが大きく変化する様子が再現できていることが分かる。一方で、橋桁下部のフランジ周りに形成される渦状の流れは、機械学習モデルの予測結果でも確認できる。しかしながら、風上側にかけての詳細な流れは再現できておらず、数値シミュレーションの結果と乖離が生じた。このような風の場の局所的な違いにより、飛来塩分粒子の到達範囲に差が生じたと考えられる。

以上より、飛来塩分粒子の到達範囲が広がる傾向が見られるが、風向きに応じた飛来塩分粒子の数値計算にも風の場の機械学習モデル(FNO)が適用できる可能性があることが分かった。

5. 長期間の風況予測への機械学習モデルの活用

5.1 機械学習モデルの活用方法

前章で構築した風向を考慮した機械学習モデルを用いて、長期間の風況予測への活用を検討した。図-11 は、気象庁の地域気象観測システム(AMeDAS)⁶⁾より取得した、新潟県糸魚川地域の風の観測データである。観測期間は 2025 年 1 月 1 日から 2025 年 12 月 31 日であり、1 日ごとの風速お




図-11 風の観測データ




図-12 機械学習モデルが予測した長期間の風速観測結果

よび風向を取得した。この風の観測データを計算領域内に流入する風と仮定し、学習後の機械学習モデルに入力情報として与えて、計算領域内の任意の観測点における長期間の風況を予測した。

5.2 観測点における長期間の風況予測結果

観測点は、原点から長さ 3500mm、幅 3500mm、高さ 1000mm 離れた箇所であり、橋梁模型の中心に位置する。図-12 に、指定した観測点において、機械学習モデルが予測した風速観測結果を示す。年間の風速予測に要した時間は 90 秒程度であった。図に示すように、観測地点の風速は年間を通じて変動する様子が確認できる。このことから、任意の観測点における長期間の風況変動を考慮する場合は、従来手法に比べて高速な予測が可能で、効率化を図れると考えられる。

6. 結論

本研究では、機械学習を援用した塩害環境予測解析について検討を行った。その結果、機械学習による風の場の予測結果は、数値シミュレーションの計算結果と概ね一致し、その計算結果が飛来塩分粒子の予測計算にも適用できることが示された。さらに、風向を考慮した機械学習モデルを構築することで、未学習の流入風向に対する風の場の予測計算に適用できるとともに、長期間における風況予測やその風の場を飛来塩分粒子の計算入力条件として利用できることが示された。

参考文献

- 1) 豊田颯太, 崎原康平, 請舛 慧, 富山 潤: 沿岸域に位置する鉄筋コンクリート構造物の各部材に付着する塩分の数値解析的検討, コンクリート工学年次論文集, Vol.45, No.1, 2023
- 2) 中村文則, 井野裕輝, 大原涼平, 下村 匠: 橋桁表面に到達する海水飛沫粒子の到達量および粒径分布の現地観測とその数値解析, 日本材料学会コンクリート構造物の補修・補強・アップグレード論文報告集, 第 18 巻, pp.317-322, 2018.10
- 3) 中村文則, 下村 匠, 大原涼平, 細山田得三: 飛来塩分の予測シミュレーション技術の開発と構造物の長期的な塩害環境評価への適用, 土木学会論文集 E2, Vol.75, No.2, pp.60-79, 2019.4
- 4) W.Peng, S.Qin, S.Yang, J.Wang, X.Liu, L.Wang: Fourier neural operator for real-time simulation of 3D dynamic urban microclimate, Building and Environment, Vol.248, pp.1-14, Jan.2024
- 5) Z.Li, N.Kovachki, K.Azizzadenesheli, B.Liu, K.Bhattacharya, A.Stuart, A.Anandkumar: Fourier neural operator for parametric partial differential equations, ICLR, 2021
- 6) 国土交通省 気象庁: 過去の気象データ検索, <https://www.data.jma.go.jp/stats/etm/>, (2026/02/15 閲覧)