

1. はじめに

河道部の流動・水質解析においては、物理過程や生物化学過程を考慮した数値モデルが用いられることが多い。しかしながら、感潮域や分合流部付近のように流動が複雑な水域においては、流動水質モデルによる水理水質現象の再現・予測は困難であることが多い。本研究では、河川感潮域における水質変動予測の手法として、ニューラルネットワーク（以下 NN と表記する）と、NN を高度化した新たな手法である深層学習を用いた解析を行い、その予測精度と適用性について検討した。さらに、積層オートエンコーダを用いた非線形主成分分析を行い、水質変動要因の抽出を試みた。

2. 対象領域

本研究では、大阪市内を流れる東横堀川の上流水門外側の溶存酸素濃度 DO を予測対象とした。予測地点の周辺図を図-1 に示す。予測地点は感潮域に位置し、潮汐による水位変動や塩水遡上の影響を受けている。また、上流からは大川と寝屋川から 2 種類の河川水が流下している。大川の水質は比較的清浄であるのに対し、寝屋川の水質は汚濁しているため、その混合割合によって予測地点の水質は大きく変動する。

東横堀川の上流端は普段は水門で閉ざされており、潮汐周期にあわせて開閉することで清浄な大川河川水を導水し、水質の保全が図られている。しかし、水門操作は水門外の水位のみに基づいて行われており、寝屋川の汚濁水を導水しているケースが確認されている。

水門操作の改善には、導水される上流水門外の河川水の水質を精度良く予測することが重要であるが、予測地点周辺では潮汐や水質の異なる水塊の混合により複雑な流動・水質構造が形成されている。

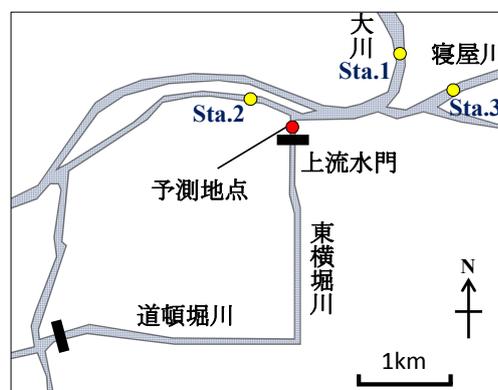


図-1 対象領域

3. 方法

NN は神経回路網を模した回帰モデルであるが、深層学習は NN を多層化することでより複雑な回帰式を構築する手法である。本研究では、NN モデルとして①階層型 3 層 NN と②階層型 7 層 NN を、深層学習モデルとして③オートエンコーダによる事前学習を施した階層型 7 層 NN と④中間層に LSTM ユニットの適用した再帰型 3 層 NN を用いた。③は事前学習により多層 NN の学習を可能にしたものである。また、④の LSTM ユニットとは内部に記憶機構を持たせたものであり、中間層に再帰構造を構築することで時間方向に多層化している。

各モデルの中間ユニット数を表-1 に示す。全てのモデルにおいて、平均二乗誤差 RMSE を学習における損失関数とした。階層型 NN では Adam を用いた確率勾配降下法で学習を行い、再帰型 NN では 48 時刻毎に Adam による誤差逆伝播を行った。出力層以外のユニットの活性化関数には ReLU 関数、出力層には恒等関数を採用した。

解析に使用するデータを得るために、図-1 に示す予測地点と Sta.1~3 において自記式水質計による 10 分間

表-1 モデルの中間ユニット数

モデル	中間ユニット数				
①階層型 3 層	10				
②階層型 7 層	34	34	34	34	10
③階層型 7 層 (事前学習)	34	34	34	34	10
④再帰型 3 層 (LSTM)	50				

間隔の連続計測を行った。ここでは 2015/8/17~10/30 に得られたデータを解析に使用し、9/15~9/30 のデータを NN のテストデータとして予測精度の評価に用い、残りをトレーニングデータとした。

NN への入力データには、予測時刻を現在としたときの 2 時間前の大川導水量、現在の大阪港潮位、直前の干潮位、直前の干潮からの経過時間、日累積降雨量 (1, 2, 3 日前) の 7 データ、さらに Sta.1~3 における DO, 電気伝導度 EC, 水温 (それぞれ 1, 2, 3 時間前) の 27 データの計 34 データを用いた。

4. 結果と考察

(1) 全ての入力データを用いた予測

表-2 に各モデルによる予測値と観測値の誤差 RMSE と相関係数を示す。最も予測精度が高かったモデルは、③事前学習を行った階層型 7 層 NN であった。図-2 にその予測値と観測値の時系列比較を示す。DO に関しては通常の NN モデルに比して深層学習モデルの RMSE が低い値を示し、深層学習の適用により精度が向上することが示された。

(2) 入力データに大川導水量、気象、潮位データのみを用いた予測

Sta.1~3 における水質のモニタリングデータが得られない場合を想定し、大川導水量、日累積降雨量、潮位等の 7 データのみを入力データとして、①階層型 3 層 NN による予測を行った。図-3 に予測結果を示す。RMSE は 14.2%, 相関係数は 0.69 となり、(1) の場合と比べて変動ピークの再現性が低下しているものの、観測値の変動をある程度追従できている。

(3) 積層オートエンコーダによる主成分の抽出

モデル③において積層エンコーダの適用により構築した NN の中間層より、入力データと高い相関を示す特徴量を主成分として抽出した。

一例として、特に高い相関を示した特徴量と入力データの組み合わせを表-3 に示す。第 1 主成分は Sta.1 の EC との間特に高い相関を示し、Sta.1 における EC の変動が雨水の流入による希釈効果を反映しているものと考え、第 1 主成分は流域の降雨状況に関係していると推察される。また、第 2 主成分は Sta.1~Sta.3 における水温との相関がいずれも高く、DO 変動が河川水温の影響を強く受けていることが示唆された。

5. おわりに

本研究では NN と深層学習を用いて河川感潮域の DO の予測を行った。その結果、NN モデル、深層学習モデルはともに DO の変動を良好に予測し、手法の有用性が示された。また、NN モデルに比べて深層学習モデルの RMSE は低く、予測精度が向上することが示された。

謝辞 調査にあたり、大阪市建設局の方々には多大なご協力を賜りました。ここに記して謝意を表します。

表-2 予測精度

モデル	DO (%)	
	RMSE	相関係数
①階層型 3 層	11.3	0.82
②階層型 7 層	11.8	0.78
③階層型 7 層 (事前学習)	10.5	0.83
④再帰型 3 層 (LSTM)	11.0	0.82

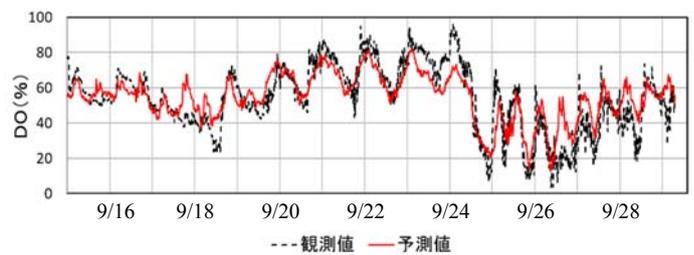


図-2 モデル③による予測値と観測値の時系列比較

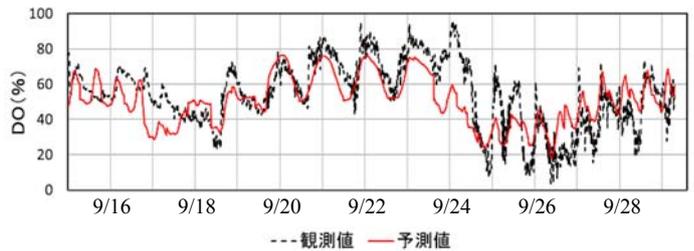


図-3 Sta.1~3 の水質データを使用しない場合の結果

表-3 抽出された主成分と相関の高い入力データ

第 1 主成分		第 2 主成分	
EC(Sta.1)	R=0.80	水温(Sta.3)	R=0.82
DO(Sta.1)	R=0.62	水温(Sta.2)	R=0.82
DO(Sta.2)	R=0.55	水温(Sta.1)	R=0.81