

流量・水温法データのAI機械学習による雨天時浸入水量解析の研究

佐藤 克己 中根 進 高橋 岩仁
保坂 成司 森田 弘昭

要旨: 筆者らは、AI機械学習の1つであるニューラルネットワークを使い、計測した水温から降雨による低下水温を推定し、計測期間中の計測水温の総和に対する降雨による低下水温の総和の比を求め、この比と成分分解で得られた非超過確率を比較することにより、非超過確率が降雨による水温低下を表すことを示した。また、同一地点で水温と流量を計測し、これをニューラルネットワークで雨天時浸入水量割合を推定し、非超過確率との相関性があることを確かめ、非超過確率が雨天時浸入水量割合を表すことを示した。

本研究では、機械学習を使って計測した流量を教師データとしてそこから推定流量を、さらに推定晴天時流量を導いた。そして、この解析にはニューラルネットワーク手法が最もよく再現でき、有効であることを確認した。また、水温法解析に適した説明変数の選定や水温データの適正な計測間隔と調査面積について考察した。あわせて流量や水温のいずれの計測によっても、計測点間の雨天時浸入水量の多寡を評価ができることを示した。

キーワード: 水温法、AI、機械学習、ニューラルネットワーク、雨天時浸入水量、雨水浸入強度

1. はじめに

中根は、雨天時浸入水量を推定するために計測、あるいは処理場などの管理記録にある時系列水量データを図-1に示すAI機械学習の1手法であるニューラルネットワーク¹⁾を使って計測流量を目的変数に、降雨量データ、時刻・曜日・月別カテゴリを説明変数として回帰する手法を開発した²⁾。図-1に示す通り、機械学習には種々の手法があり、ニューラルネットワークは河川における流量予測³⁾、流出解析⁴⁾、水位予測^{5), 6)}、および洪水予測^{7), 8), 9), 10)}によく用いられ、研究されているが、下水道における雨天時浸入水量予測に関してはあまり活用されていないのが現状である。

一方、筆者らは、污水管きょ内の下水温を定点で定時計測する水温法によって、①定点での晴天時と雨天時の水温データを比較観察することで、その上流域の雨天時浸入水や常時浸入水を確認、②スパンの上・下流マンホール内の水温を比較することで誤接合などによる雨天時直接浸入水を確認している¹¹⁾。また、水温法で得られた時系列水温データを成分分解し、晴天時と雨天時に分け、その晴天時と

雨天時の水温分布の違い(差)を非超過確率(検出力)で表した。次に、ニューラルネットワークを使い、

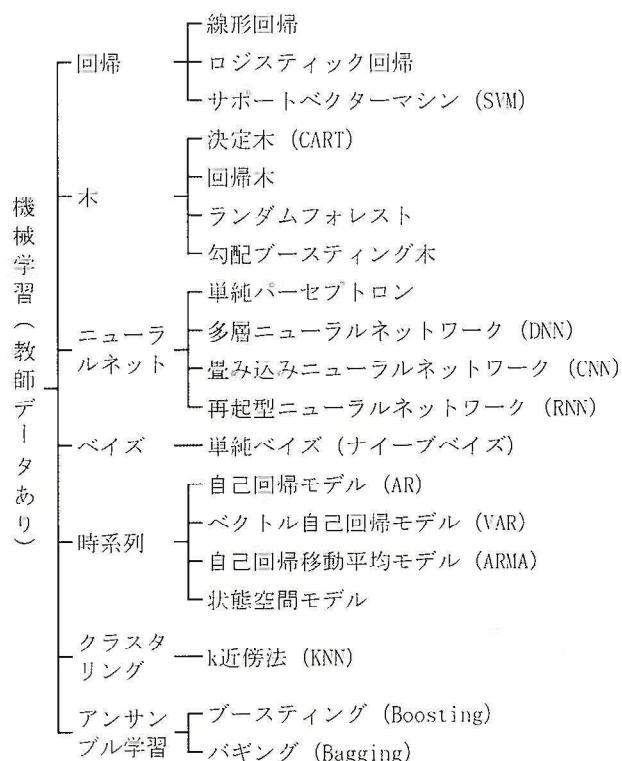


図-1 AI機械学習の学習技術

計測した水温の降雨による低下水温を推定し、計測期間中の計測水温の総和に対する降雨による低下水温の総和の比を求め、この比と非超過確率を比較することにより、非超過確率が降雨による水温低下を表すことを示した。また、一部の水温計測点で流量調査を行い、これもニューラルネットワークで雨天時浸入水量割合（＝総雨天時浸入水量／総流量）を推定し、非超過確率との相関性があることを確かめ、非超過確率が雨天時浸入水量割合を表すことを明らかにした¹²⁾。

本研究は、まず種々開発されている機械学習手法を使って、計測流量を教師データ、降雨量などを説明変数として、流量を回帰・推定し、さらに、その学習結果から降雨量のない説明変数を使って降雨時の晴天日流量を推定した。そして、いくつか機械学習手法の中で計測流量をもっともよく回帰（再現）できる雨天時浸入水量解析に適した学習法を示した。次に、水温法の解析においては、計測水温を教師データとし、解析に適した説明変数の選定や使用する水温データの適正な計測間隔、水温センサ当たりの調査面積について考察を行った。また、機械学習解析の回帰具合を向上させるために必要な説明変数の留意事項について検討した。

2. 調査方法の概要

調査地は、関東地方にある地方都市の住居地域であり、分流式下水道で整備されている。調査対象はこの地域の污水管きょとした。調査区域は総面積403.7haであり、路線系統（流域）の流末マンホール内に水温計測点を設置した。本研究では、このうち調査場所が離れて路線系統が異なり、面積が同程度の計測点A(21.6ha)と計測点B(18.9ha)を選定して解析を行う。水温計測後に同計測点で流量調査を行った。調査時期は、水温調査を2018年6月29日から12月6日、流量調査を2019年6月15日から7月15日の2ヵ月にかけて行った。なお、流量調査時には確認のため、水温を1時間間隔のスポット調査も併せて行った。

水温調査に使用する水温センサは、計測範囲が-10°C～85°C、精度が±0.5°Cであり、JIS C 1604におけるCクラス以上の許容度であり、計測点管底部に設置した。一方の流量調査は、PBフリューム式流量計を使用し、計測点マンホール底部に据え付けた。また、降雨量は、計測区域のほぼ中央に位置する建屋屋上1ヵ所に転倒ます式雨量計（最小計測量；0.5mm）を設置、計測した。

3. 時系列流量データ解析に適した機械学習手法

3.1 機械学習手法の選定と説明変数

図-1に示した機械学習のうち、前述したように河川の水位予測や洪水予測によく活用されているニューラルネットワーク、そしてサポートベクターマシン^{13), 14), 15), 16)}、ベクトル自己回帰モデル^{17), 18), 19)}、ランダムフォレスト^{20), 21), 22), 23)}の4手法を選定した。4手法のうちベクトル自己回帰モデル以外の3手法については、すべて同じ表-1のデータ構成に示す説明変数を使って目的変数とする計測流量を推定（以下、推定流量という）する。ベクトル自己回帰モデルについては、自己回帰性を利用する手法であるため、正規化した数量データ（流量、降雨量）のみを48時間遡って使用し、計測流量と推定流量の一致具合（以下、回帰具合という）を比較する。時系列データの解析には、表に示す説明変数を、数量データ（流量、降雨量）については正規化し、質的データはカテゴリ化して0, 1データに変換して行う。次に、機械学習した結果を使って時系列データのうち降雨量データを全て0としたデータを作り、再計算することによって晴天時流量を推定（以下、推定晴天時流量という）する。

3.2 流量における機械学習結果と回帰具合

計測点Aにおける計測期間中の計測流量と機械学習によって回帰した推定流量の関係、そして推定流量と推定晴天時流量の関係について、ニューラルネットワークは図-2, 3に、サポートベクターマシンは図-4, 5に、ベクトル自己回帰モデルは図-6, 7に、ランダムフォレストは図-8, 9にそれぞれ示す。図-3, 5, 7, 9については、図に示す45°の線

表-1 流量解析のデータ（説明変数）構成

データ項目	データ構成
教師データ	・計測流量
目的変数	・推定流量
説明変数	
質的データ	・時刻カテゴリ（1時間間隔） ・曜日カテゴリ： • 月別カテゴリ： • 小計 24個 ^{*1} 7個 ^{*2} 2個 ^{*3} 小計 33個
量的データ	・1時間降雨量データ： • 小計 48個 ^{*4} • 合計 48個

*1 時刻カテゴリ：1日（24時間）の流量の周期性を表す

*2 曜日カテゴリ：1週間の生活活動の変動を表す

*3 月別カテゴリ：調査期間2か月の季節変動を表す

*4 対象とする計測流量の降雨の影響がある時刻（2日分）まで遡る降雨量の1時間間隔データ

($y = 1.0 x$) より上のプロットが雨天時浸入水を示しており 45° の線との差が雨天時浸入水量となる。

機械学習が計測流量を良好に回帰できていれば、計測流量と推定流量の関係を示すグラフの傾きは 45° になり、計測流量と推定流量の差は小さくなる。図-2, 4, 6, 8 中に回帰式と Nash 係数を示した。Nash (Nash-Sutcliffe) 係数とは、河川の洪水流量解析に際し、洪水流量と推定洪水流量の回帰具合を表すために多く使われ^{24), 25)}、本研究の機械学習における回帰具合もこれに倣い Nash 係数を用いた。なお、Nash 係数は、1.0 を最大とし 1.0 に近いほどモデルの精度はよいとされ、0.7 以上でモデルの再現性が高いとされている²⁶⁾。

$$y = 1.0 x$$

ここに、
 y : 推定流量 m^3/hr
 x : 計測流量 m^3/hr

Nash-Sutcliffe 係数

$$Nash = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

ここに、

$Nash$: Nash 係数
 y_i : i 時の計測値
 \hat{y}_i : i 時の推定値
 \bar{y} : 計測値の平均値
 n : データ数

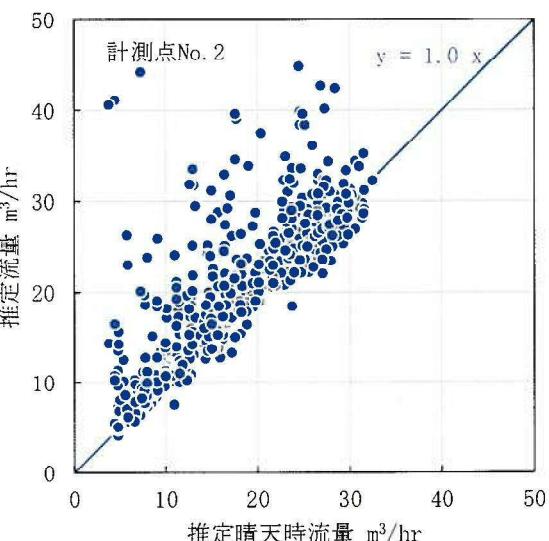
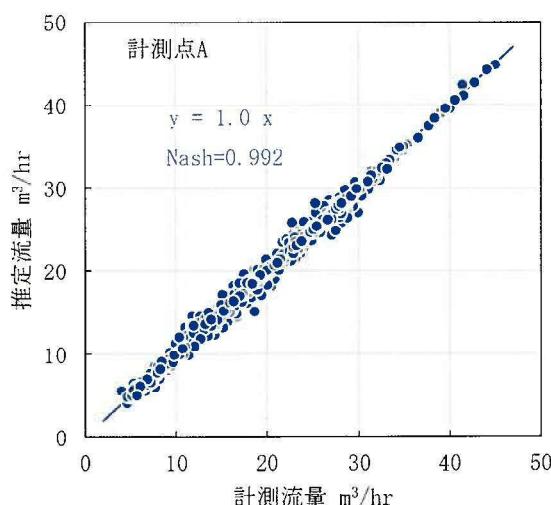


図-3 ニューラルネットワークによる推定晴天時流量と推定流量の関係

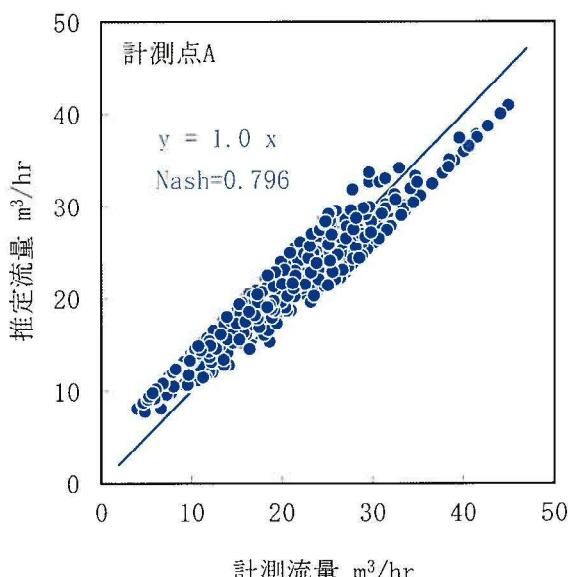


図-4 サポートベクターマシンによる計測流量と推定流量の関係

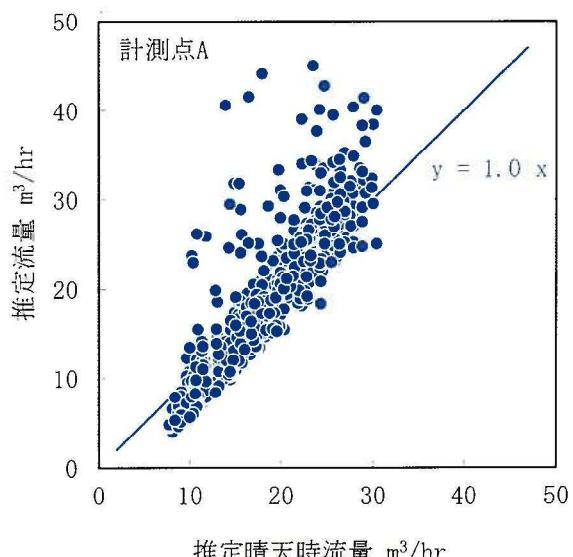


図-5 サポートベクターマシンによる推定晴天時流量と推定流量の関係

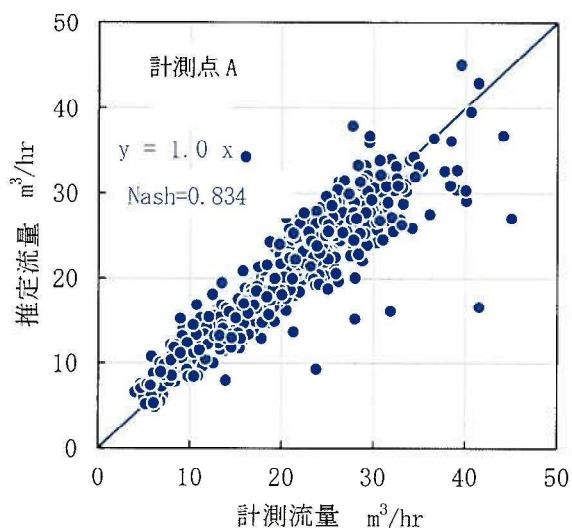


図-6 ベクトル自己回帰モデルによる計測流量と推定流量の関係

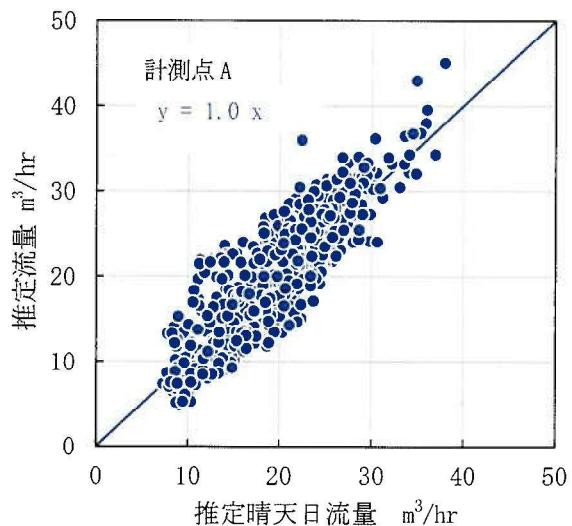


図-7 ベクトル自己回帰モデルによる推定晴天時流量と推定流量の関係

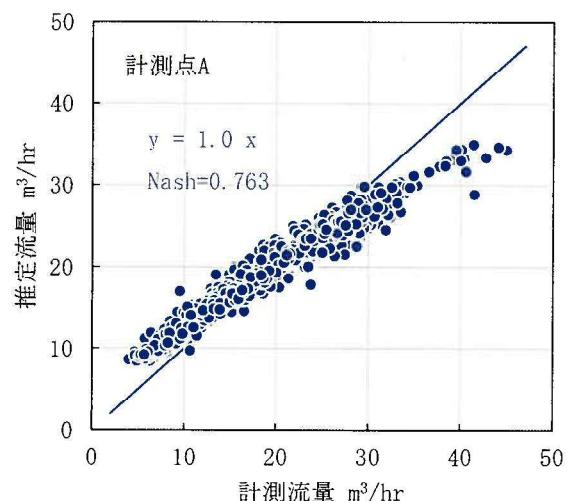


図-8 ランダムフォレストによる計測流量と推定流量の関係

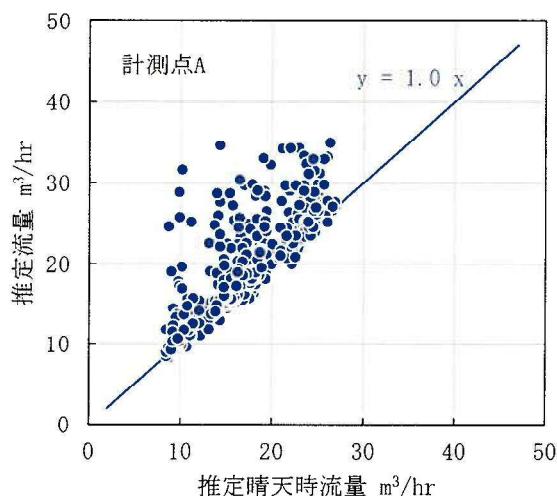


図-9 ランダムフォレストによる推定晴天時流量と推定流量の関係

表-2 計測流量と推定流量の回帰具合

機械学習手法	Nash係数
ニューラルネットワーク	0.992
サポートベクターマシン	0.796
ベクトル自己回帰モデル	0.834
ランダムフォレスト	0.763

4手法の回帰具合を表-2に示す。4手法ともNash係数は0.7を超え、モデルの再現性は高いといえるが、ニューラルネットワークのNash係数は突出して高く、非常に適合性が高い。

3.3 降雨量と雨天時浸入水量、晴天日計測流量と推定晴天時流量について

ニューラルネットワークで計算した図-3のある日の降水量、推定流量、および推定晴天時流量の時刻推移の一例を図-10に示す。図中の網掛け部分が雨天時浸入水量であり、図-3の45°の線より上側の流量差がこの網掛け部に相当する。なお、図中の推定流量と計測流量がほぼ重なって見えるのは、回帰具合が高いためである。

一方、晴天日の計測流量と推定晴天時流量の関係を図-11に示す。図より、晴天日の計測流量と推定晴天時流量はよく一致、再現できている。また、推定晴天時流量と推定流量は晴天日のため、重なっている。

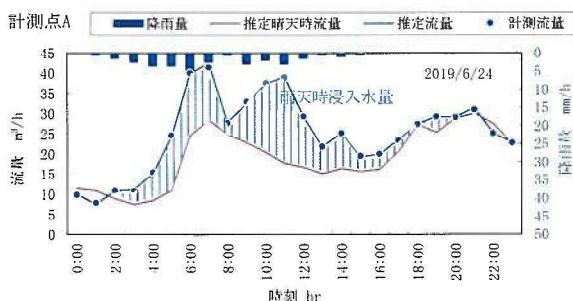


図-10 降雨日の降雨量、推定流量、推定晴天時流量の推移

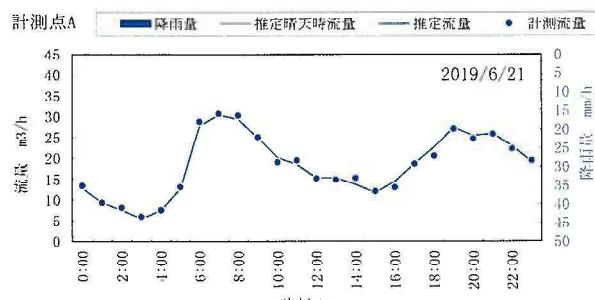


図-11 晴天日の計測流量、推定流量、推定晴天時流量の推移

3.4 流量計測による雨天時浸入水量解析

計測点Aと同時期に計測した計測点Bにおけるニューラルネットワークで解析した、推定晴天時流量と推定流量の関係を図-12に示す。図-3の計測点Aとの比較になるが、計測点Bは計測点Aより45°の線から上の推定流量との差が小さく雨天時浸入水量は計測点Aより少ないと判断できる。

図-3ならびに図-12をより詳細に検討するためには、計測点Aと計測点Bのそれぞれの概要とニューラルネットワークによる解析結果を表-3に示す。両計測点とも⑥総推定流量そして⑧総雨天時浸入水量を定量化でき、さらに⑨管路延長当たり雨天時浸

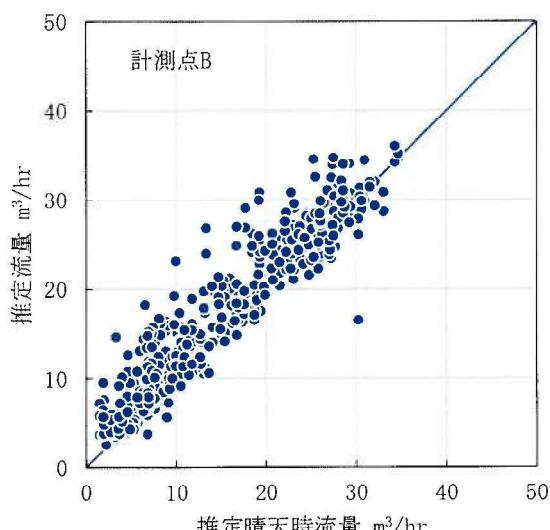


図-12 計測点Bのニューラルネットワークによる推定晴天時流量と推定流量の関係

表-3 計測点A、Bの概要とニューラルネットワークによる解析結果の比較

概要・解析結果	単位	計測点A	計測点B	備考
土地利用形態	—	住居地域	住居地域	
①調査(追加)面積	ha	21.6	18.9	
②管路延長	m	4,928	5,177	
③総降雨量	mm		212	
④総計測流量	m^3	14,855	12,323	
⑤追加面積当たり流量	m^3/ha	688	652	
⑥総推定流量	m^3	14,852	12,324	
⑦総推定晴天時流量	m^3	13,346	11,205	
⑧総雨天時浸入水量	m^3	1,506	1,119	=⑥-⑦
⑨管路延長当たり雨天時浸入水量	m^3/m	0.306	0.216	=⑧÷②
⑩雨天時浸入水量割合	%	10.1	9.1	=⑧÷⑥
⑪雨水浸入強度 ²⁷⁾	%	3.3	2.8	=⑧÷(①×③×10)

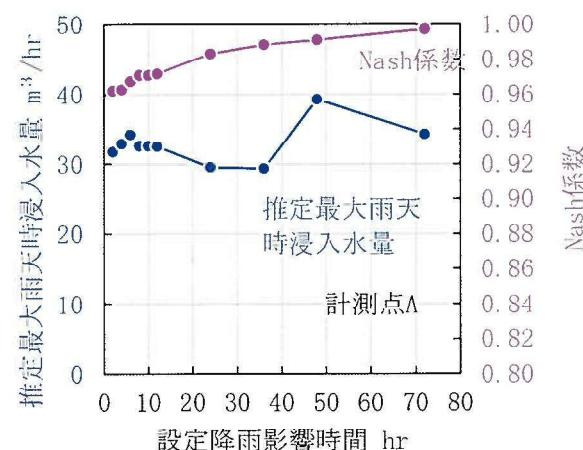


図-13 降雨影響時間の設定と推定雨天時浸入水量およびNash係数の関係

入水量、⑩雨天時浸入水量割合²⁷⁾、⑪雨水浸入強度²⁷⁾の解析結果は計測点Aが計測点Bより浸入水量が多いことを示している。このことは図-3と図-12の比較結果と一致する。雨水浸入強度は文献²⁷⁾の通り、直接浸入水強度と浸透浸入水強度の和であり、単位面積当たり単位雨量当たりの雨天時浸入水量をいう。分母の(総降雨量 mm × 面積 ha × 10) m^3 が、計測期間中に調査面積に降った雨量の総量を示す。

3.5 降雨影響時間の検討と設定

降雨による雨天時浸入水量の影響は、2, 3日継続するといわれ、文献²⁸⁾では、晴天日流量の抽出は降雨日後3日空けた次の日としている。

本研究においては、降雨による影響時間を検討するため、影響時間を2, 4, 6, 8, 10, 12, 24, 36, 48, 72時間と変えてニューラルネットワークで流量を解析し、雨天時浸入水量を推定した。

設定した降雨影響時間と推定雨天時浸入水量の関係を図-13に示す。併せて各設定降雨影響時間における回帰具合をNash係数で示す。設定降雨影響時

間が長くなるに従い、徐々に Nash 係数は高くなる。Nash 係数が高くなるのは、説明変数のデータ数が多くなるためである。雨天時浸入水量は、48 時間の影響時間が最大値を示した。解析の目的が雨天時浸入水量を把握することであるため、浸入水量を顕著に表すことができ、Nash 係数が高く回帰具合が良い 48 時間を降雨影響時間に採用して解析することとした。

4. ニューラルネットワークによる水温法解析に適した説明変数

4.1 水温の長期変動と説明変数

水温法のニューラルネットワークによる解析は、予備解析をした結果、3 章の流量解析とは異なり、降雨による影響時間を長く設定すると水温の影響（水温低下）を表すことができないため、2 時間分に設定した。ニューラルネットワークによる水温解析に使用する説明変数（入力層データ）のデータ構成を仮に表-4 とする。

ニューラルネットワークで回帰した推定水温から、流量の解析と同様に降雨量をなし（0）として再計算し、雨天時の推定晴天時水温を推定する。

水温法をニューラルネットワークで表-4 に示す

表-4 水温解析のデータ（説明変数）構成

データ項目	データ構成
教師データ	・計測流量
目的変数	・推定流量
説明変数	
<input type="checkbox"/> 入力層データ：時刻カテゴリ（1時間間隔）	
質的データ	<ul style="list-style-type: none"> ・時刻カテゴリ： 24個^{*1} ・曜日カテゴリ： 7個^{*2} ・月別カテゴリ： 2個^{*3} 小計 33個
量的データ	<ul style="list-style-type: none"> ・1時間降雨量データ： 48個^{*4} 小計 48個 合計 81個

*1 時刻カテゴリ：1日（24時間）の流量の周期性を表す

*2 曜日カテゴリ：1週間の生活活動の変動を表す

*3 月別カテゴリ：調査期間 2か月の季節変動を表す

*4 対象とする計測流量の降雨の影響がある時刻（2時間分）まで遡る降雨量の1時間間隔データ

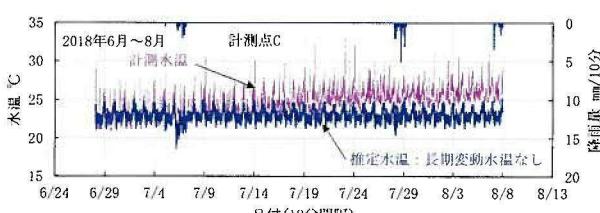


図-14 降雨量とカレンダー情報での計測水温と推定水温の関係

説明変数を使って解析した推定水温結果を図-14 に示す。マゼンタ色で表した計測水温は、時間的な変動があるとともに、夏に向かって徐々に水温が高くなる様子がわかる。一方の解析した推定水温（青色）は、計測水温をよく再現できておらず、季節の移行とともに乖離が大きくなっている。このことは、下水温は季節の移行に伴う水温変動がみられることであり、流量解析と同じ説明変数では季節変動といった長期的な水温変動を表せていないことである。

長期水温変動を表すため、カレンダー情報の6月、7月といったカテゴリ変数（表-4 の月別カテゴリ）を使っているが、10 分当たりの時系列データに対してこの月別カテゴリ変数による推定水温の動きが乏しいことが判明した。そこで、長期変動を表現するため、水温データを成分分解して抽出した長期変動水温¹²⁾を正規化して説明変数に追加することにした。

成分分解の長期変動水温は、移動平均法で10 分当たり水温の時系列データを用い、時点ごとを中心にして1日の周期分（144 個（= 24 時 × 60 分 ÷ 10 分））の計測水温を平均した値である。

この際の水温解析データの説明変数のデータ構成を表-5 に示す。

表-4 の説明変数から表-5 の 10 分間隔の説明変数に変えて、ニューラルネットワークにより解析し

表-5 水温解析のデータ（説明変数）構成

データ項目	データ構成
教師データ	・計測水温
目的変数	・推定水温
説明変数	
<input type="checkbox"/> 入力層データ：時刻カテゴリ（10分間隔）	
質的データ	<ul style="list-style-type: none"> ・時刻カテゴリ： 144個 ・曜日カテゴリ： 7個 小計 151個
量的データ	<ul style="list-style-type: none"> ・降雨量データ： 12個^{*1} ・長期変動水温： 1個^{*2} 小計 13個
	合計 164個
<input type="checkbox"/> 入力層データ：時刻カテゴリ（1時間間隔）	
質的データ	<ul style="list-style-type: none"> ・時刻カテゴリ： 24個 ・曜日カテゴリ： 7個 小計 31個
量的データ	<ul style="list-style-type: none"> ・降雨量データ： 2個^{*3} ・長期変動水温： 1個^{*2} 小計 3個
	合計 34個

*1 対象とする計測水温の降雨の影響がある時刻（2時間分）まで遡る降雨量の10分間隔データ

*2 既報¹³⁾で成分分解した長期変動水温を正規化したデータ

*3 対象とする計測水温の降雨の影響がある時刻（2時間分）まで遡る降雨量の1時間間隔データ

た結果を図-15に示す。月別カテゴリではなく、長期変動水温を説明変数にすることで、計測水温の回帰具合が良くなることが確認できたことから、水温法解析に使用する説明変数には長期変動水温を採用することにした。

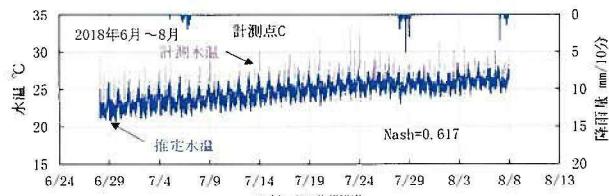


図-15 降雨量とカレンダー情報+長期変動水温での計測水温と推定水温の関係

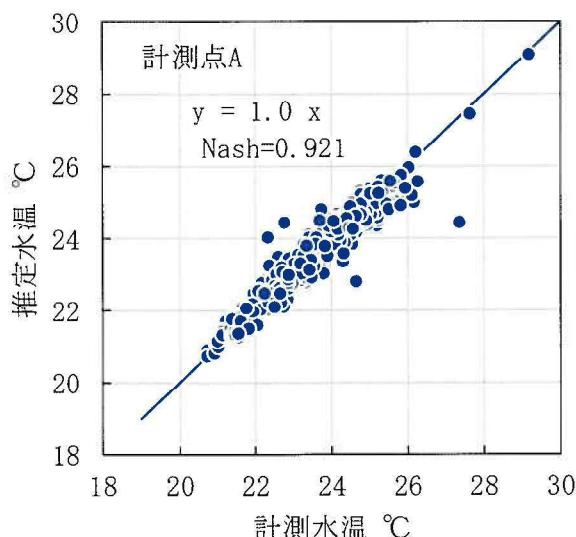


図-16 計測水温と推定水温の関係

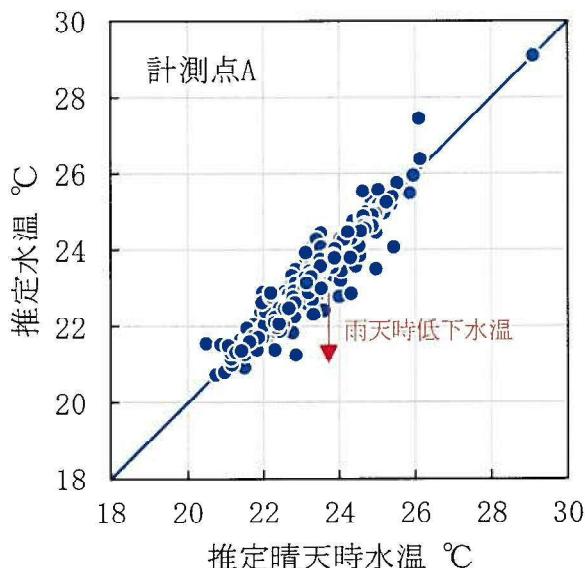


図-17 推定晴天時水温と推定水温の関係（計測間隔：1時間）

4.2 水温の計測間隔と説明変数

4.2.1 時刻カテゴリを1時間間隔とした解析

(1) 2019年6月～7月から抽出したデータの解析

3章に示した流量測定と同時に、管路内水温を1時間間隔にスポット的に測定した。

この1時間間隔水温の時系列データを使い、ニューラルネットワークで計測点Aの計測水温を回帰する。

計測水温と推定水温の関係を図-16に示す。推定晴天時水温と推定水温の関係は、雨天時浸入水があれば水温が低下し、45°の線から下側に打点されるはずであるが、図-17に示すように45°の線の上下両側に打点されており、雨天時浸入水による水温低下を表せていない。

(2) 2018年7月～12月から抽出したデータの解析

(1)の2019年の計測は、計測期間が短いことなどを考慮して、10分当たりデータが利用できる計測期間が長い(2018年7月～12月)時系列データを使い、この1時間間隔データと10分当たりデータを説明変数の時刻カテゴリにしてニューラルネットワークにより水温解析を行い比較する。

まず、1時間間隔の時系列データは10分当たりの時系列データから1時間ごとに正時水温を抽出して作成し、ニューラルネットワークで推定水温を解析、さらに推定晴天時水温を求めた。その結果を図-18に示すが、45°の線より下側に打点はあるものの回帰上の差と見分けがつかない状態であり、1時間間隔の水温データでは、計測期間の長短に関わらず降雨の影響を表せていない。

4.2.2 時刻カテゴリを10分間隔とした解析

次に、10分間隔の時刻カテゴリで解析した推定

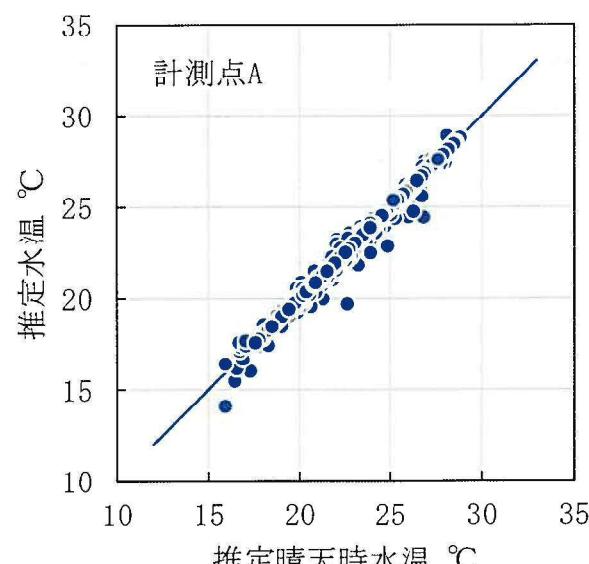


図-18 推定晴天時水温と推定水温の関係（計測間隔：1時間）

晴天時水温と推定水温の関係を図-19に示す。45°の線の下側にプロットされたものが雨天時浸入水の影響によるものであり、10分当たりの時系列データを用いた解析では雨天時による水温の低下を表現できている。なお、計測水温と推定水温のNash係数は、図は掲載していないが0.963である。

以上のことから、ニューラルネットワークの解析では、10分間隔のデータを用いることで水温変動を捉えて雨天時浸入水を推定できること、一方の1時間間隔の時系列データでは、浸入水による水温低下が把握できないことが判明した。

図-20は、計測点Bについて10分間隔のデータで解析し、推定晴天時水温と推定水温の関係を示したものである。計測点Bにおいても雨天時浸入水による水温低下が見られる。

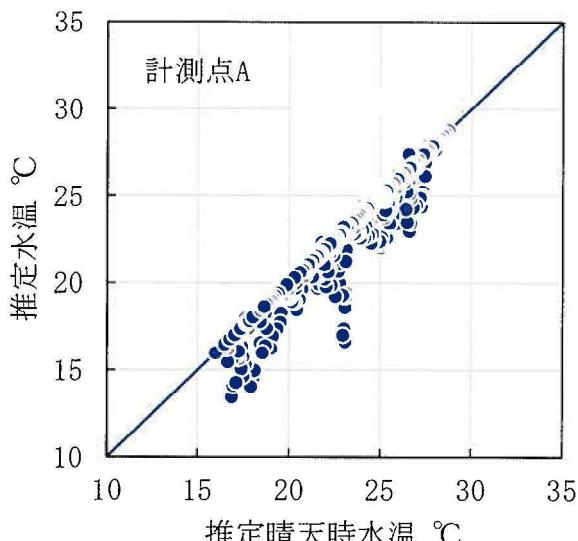


図-19 推定晴天時水温と推定水温の関係（計測間隔：10分）

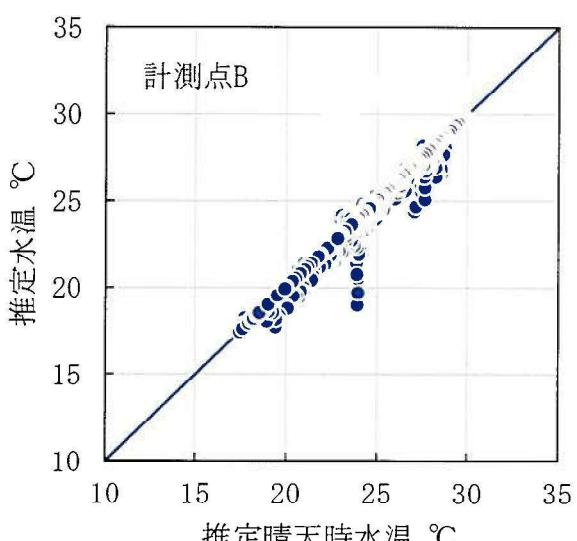


図-20 推定晴天時水温と推定水温の関係（計測間隔：10分）

4.2.3 時刻カテゴリによる回帰具合

ニューラルネットワークを使った水温法の解析を行うにあたって、①質的データの時刻カテゴリを1時間間隔データ、量的データの降雨量データを1時間降雨量データにした場合、②質的データの時刻カテゴリを10分間隔データ、量的データの降雨量データを10分降雨量データにした場合の解析結果についてNash係数を使って表-6に示す。表に示す通り、質的・量的データを1時間間隔から10分間隔にすることでNash係数が大きく、すなわち水温法の解析精度が向上する。また、図-18と19を比較すると10分間隔の水温データで解析した方が1時間間隔データより、雨天時浸入水による水温低下をよく再現できていることがわかり、これは計測点Bでの解析結果である図-20からも判断できる。

表-6 ニューラルネットワークによる水温法解析での時刻カテゴリによるNash係数

水温法解析での時刻カテゴリ	Nash係数
① 1時間間隔	0.921
② 10分間隔	0.963

5. ニューラルネットワークによる流量、水温法の解析結果

ニューラルネットワークを使った計測点AおよびBの流量解析は表-3に示したが、これと時刻カテゴリ10分間隔での水温法解析結果を表-7にまとめて示す。

水温法解析においても、流量解析の雨天時浸入水量割合に相当する総低下水温°C/総推定水温°C、さらに雨水浸入強度に相当する総低下水温°C/総降雨量m³(降雨量mm × 面積ha × 10)のいずれも、

表-7 ニューラルネットワークによる流量、水温法の解析結果

解析対象と調査日時	総降雨量と解析結果	計測点A	計測点B
流量解析 2019年 自 6月15日 至 7月15日	総降雨量(mm)	212	
	管路延長当たり雨天時 浸入水量(m³/m)	0.306	0.216
	雨天時浸入水量割合 (%)	10.1	9.1
	雨水浸入強度(%)	3.3	2.8
水温法解析 2018年 自 6月29日 至 12月16日	総降雨量(mm)	545	
	総低下水温(°C)/ 総推定水温(°C)	0.10	0.07
	総低下水温(°C)/総降 雨量m³(降雨量(mm) × 面積(ha) × 10)	0.0049	0.0040

計測点間の雨天時浸入水量の多寡を示すことが可能であった。

次に、表-7に示す総低下水温°C / 総降雨量 m³ (降雨量 mm × 面積 ha × 10) と各計測点の雨水浸入強度の関係を図-21に示す。

雨天時浸入水量を把握するために、機械学習によって流量や水温から推定する場合、計測の調査時期が異なると、気温や降雨量といった環境条件も変わる。本研究では、流量による解析と水温法の解析に使用したデータの計測時期は異なるが、図-21に示す通り調査時期が異なっても横軸の水温法の解析結果と縦軸の流量解析の結果に相関があることから、計測時期は異なっても計測点間の雨天時浸入水量の多寡を表現できることを確認した。

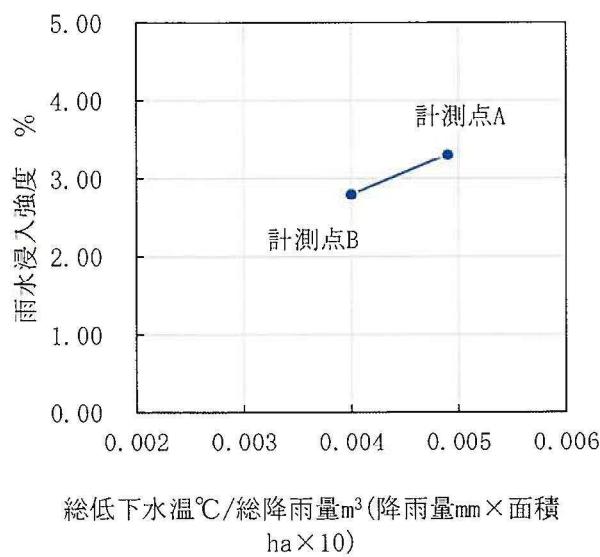


図-21 計測点 A, B の総低下水温°C / 総降雨量 m³ (降雨量 mm × 面積 ha × 10) と雨水浸入強度の関係

6. 水温解析における1計測点当たりの調査面積の検討

雨天時浸入水量による水温の影響が調査面積によってどのような傾向を示すか検討するために、調査区域内の調査面積が異なる他の計測点 16箇所についてニューラルネットワークによる解析を行った。降雨量、計測水温とも 10 分当りの時系列データを用いて、低下水温を推定し、計測期間中の総降雨量と雨水浸入強度に相当する総降雨量 m³ (降雨量 mm × 調査面積 ha × 10) に対する総低下水温の比を求め、計測点ごとの ln (調査面積 ha) との関係を図-22に示す。

各計測点における比は、雨天時浸入水量の大小により変化するが、グラフ曲線の傾きが ln (調査面積 ha) = 3.0 ~ 3.5 付近で変化していて、ln (調査面積 ha) = 4 では縦軸の値が小さすぎて読み取りづ

らい。このことから、水温法での計測点の調査面積は、20 ~ 30ha ($\approx 20.1\text{ha} (= e^{3.0}) \sim 33.1\text{ha} (= e^{3.5})$) 程度が望ましいことがわかる。

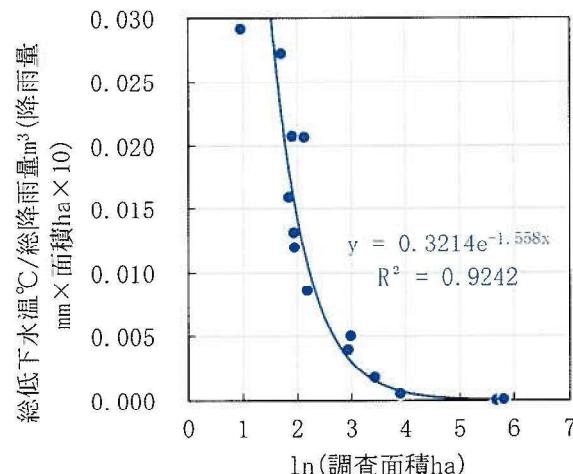


図-22 計測点ごとの ln(調査面積 ha) と総降雨量 m³ (降雨量 × 調査面積 × 10) に対する総低下水温の比の関係

7. 解析に必要な説明変数

本研究では、関東地方のある地方都市に位置する住居地域において、流量ならびに水温法による雨天時浸入水の解析をニューラルネットワークによって行った。その結果、流量による解析では表-1に示す説明変数を使用することで、一方の水温法による解析では、表-5の10分間隔の時刻カテゴリの説明変数を使用することで、それぞれの計測流量、水温を精度よく再現できた。

一方、全国的には多様な条件下に下水道管きょが敷設されており、機械学習によって雨天時浸入水量を解析する場合、本研究で使用した説明変数のみでよく回帰できるか否かは不明である。この章では、上記解析に使用した都市ではなく農村地域にある農業集落排水施設の流量データを使用して、地域の特性に合致した説明変数について検討する。

農業集落排水管理者から入手した流量データは、処理場における流入水量の維持管理記録として8月～11月末までの日当りデータである。管路施設はすべてが塩化ビニル管である。なお、解析に使用した説明変数は表-1を基本とするが、流量データが日当りデータのため、降雨量も日当りとして解析したが、うまく回帰できなかった。そこで、管理者からヒアリングした結果、①維持管理記録の範囲には8月10日～9月30日の灌漑期と10月以降の非灌漑期がある、②10月に入ると急に処理場への流入量が減少する、③農業用水が地中に浸透し、それ

が浸入水となっている可能性がある、④農業用水管と汚水管が誤接合されている可能性がある、などの情報が得られた。このため、これらの情報を灌漑カテゴリとして追加、導入した。

処理場流入水量と解析した推定流量の結果を図-23に示すが、Nash係数が0.984と極めてよく回帰できている。また、維持管理記録の期間中の流入水量（青点で表示）の推移を図-24に示すが、この図に解析した推定流量を青色で、推定晴天時流量をマゼンタ色で表す。推定流量、推定晴天時流量とともに非灌漑期になると減少していることが回帰できている。

以上より、雨天時浸入水量を機械学習によって解析する場合は、対象地域の特性や管きょ施設の布設条件などを考慮して説明変数を検討し、教師データとの回帰具合を確認する必要がある。

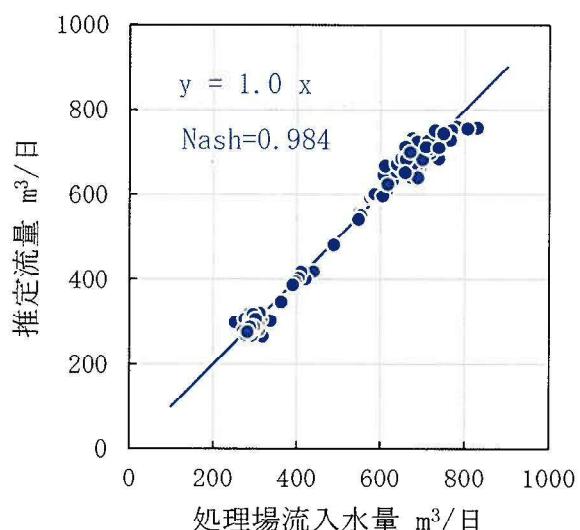


図-23 処理場流入流量と推定流量の関係

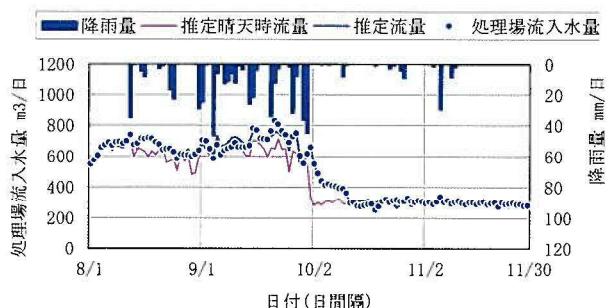


図-24 処理場流入量と推定流量および推定晴天時流量の推移

8. まとめ

本研究では、機械学習を用いて雨天時浸入水の解析を行った。得られた知見を以下に示す。

- ① 流量データを使った雨天時浸入水量解析で

は、ニューラルネットワーク、サポートベクターマシン、ベクトル自己回帰モデル、ランダムフォレストいずれの機械学習においても推定結果がNash係数0.7以上とよく回帰できた。

- ② 特にニューラルネットワークを使った解析は、Nash係数が0.992と最も高く、雨天時浸入水量の解析に有効であることを確認した。
- ③ 管路延長当たり雨天時浸入水量、雨天時浸入水量割合、雨水浸入強度から、計測点間の雨天時浸入水量の多寡を示すことができる。
- ④ 流量解析では、時系列データは1時間当たりの流量を使い、説明変数に表-1の質的データである時刻、曜日、月別カテゴリを加え、量的データとして降雨の影響時間として2日分まで遡る雨量データを追加することによって計測流量を回帰し、雨天時浸入水量を推定できる。
- ⑤ 水温法による解析では、表-5に示す通り、説明変数の時刻カテゴリは10分間隔の水温を用い、質的データである時刻、曜日カテゴリと、量的データとして降雨の影響時間として2時間分まで遡る雨量データと長期変動水温を追加することによって計測水温を回帰でき、雨天時浸入水による低下水温を推定できる。
- ⑥ 調査時期が異なるデータを使用しても流量解析、水温法解析とともに計測点間の雨天時浸入水量の多寡を評価できる。
- ⑦ 機械学習で雨天時浸入水量の解析を行う際には、農業集落排水事業での解析事例のように、対象地域や管きょ施設の特性を考慮した説明変数を見つけることが重要となる。

9. 謝辞

本研究は、令和元年度科学研究費助成事業（基盤研究（C））（課題番号：19K04670、代表者：日本大学 佐藤克己）の支援を受けて実施されました。ここに記して感謝の意を表します。

〈参考文献〉

- 1) 金明哲：Rによるデータサイエンス 森北出版株式会社 2017年3月 第2版第1刷 pp.216-227
- 2) 中根進：ニューラルネットワークを用いた雨天時浸入水を含む流量の再現、下水道協会誌 Vol.45, pp.162-169, 2008

- 3) 滝口修司, キムスンミン, 立川康人, 市川温, 萬和明: ニューラルネットワークを用いた関千知宇地域の河川流量予測における重要入力因子の抽出, 土木学会論文集B1(水工学), Vol.74, No.4, pp.1_877-1_882, 2018
- 4) 阿部清明, 菊池英明, 古川浩平, 塩月善晴: ニューラルネットワークによる流出解析手法(日流量)に関する研究, 土木学会論文集, No.656, II-52, pp.1-13, 2000
- 5) 高崎忠勝, 河村明, 天口英雄: ニューラルネットワークによる都市中小河川感潮域の水位推定, 土木学会論文集B1(水工学), Vol.67, No.4, pp.1_1603-1_1608, 2011
- 6) 一言正之, 桜庭雅明: 深層ニューラルネットワークと分布型モデルを組み合わせたハイブリッド河川水位予測手法, 土木学会論文集B1(水工学), Vol.73, No.1, pp.22-33, 2017
- 7) 梶山敏明, 外山久典, 笹原和彦, 眞間修一, 関基, 竹村仁志: ニューラルネットワークによる阿武隈川洪水予測の基礎的研究, 土木学会河川技術論文集(河川技術に関するシンポジウムv.9), pp.173-178, 2003
- 8) 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 眞間修一: 河川特性を反映したニューラルネットワーク洪水予測の精度向上, 土木学会河川技術論文集, 第10巻, pp.295-300, 2013
- 9) 一言正之, 桜庭雅明: 深層学習の適用によるニューラルネットワーク洪水予測の精度向上, 土木学会河川技術論文集, 第22巻, pp.1-6, 2016
- 10) 岡田治, 柿澤一弘, 田所正, 中安正晃: AIによる洪水予測と水位データの異常検知, 平成29年度河川情報シンポジウム, pp.3-1-3-15, 2017
- 11) 佐藤克己, 長谷川孝, 高橋岩仁, 保坂成司, 仙波不二夫, 森田弘昭: 管路内下水温の連続測定による不明水調査手法の実用化研究, 環境技術, VOL.45, pp.262-271, 2017
- 12) 佐藤克己, 中根進, 高橋岩仁, 保坂成司, 森田弘昭: 時系列水温データの成分分解による下水量解析, 下水道協会誌, Vol.57, pp.88-97
- 13) 金明哲: Rによるデータサイエンス 森北出版株式会社 2017年3月 第2版第1刷 pp.209-215
- 14) 高橋俊彦, 平山康典, 天野玲子, 武田誠, 松尾直樹: 浸水実績・降雨記録を用いた機械学習に基づく簡易浸水予測システム, 土木学会論文集B1(水工学), Vol.67, No.4, pp.1_937-1_942, 2011
- 15) 樋田祐輔, 千葉洋, 浅岡良浩, 長林久夫: 流出解析モデルと機械学習を用いた下水道管渠内水位のリアルタイム予測手法, 土木学会論文集B1(水工学), Vol.73, No.4, pp.1_649-1_654, 2017
- 16) 武田誠: 豪雨による都市浸水のモニタリングと対策支援技術の開発, 国土交通省 平成29年度 河川砂防技術研究開発 成果概要, pp.1-7, 2018
- 17) 村尾博: Rで学ぶ実証分析 時系列分析の基礎から予測まで, オーム社, 2019年12月
- 18) 内田賢悦: 水災害時のXバンドレーダ情報を使った河川水位予測に関する研究, 北海道河川財団研究所紀要(XXVII), pp.113-123, 2016
- 19) 小山直紀, 山田正: 観測水位のみを用いた時系列解析による洪水予測手法の適用性に関する研究, 中央大学理工学研究所論文集, pp.13-20, 2019
- 20) 金明哲: Rによるデータサイエンス 森北出版株式会社 2017年3月 第2版第1刷 pp.201-205
- 21) 坂本莉子, 中津川誠, 小林洋介: ランダムフォレスト法に基づく大河川の低頻度洪水の水位予測に関する研究, 土木学会論文集B1(水工学), Vol.74, No.4, pp.1_1375-1_1380, 2018
- 22) 岡崎亮太, 中津川誠, 小林洋介: ランダムフォレスト法による洪水時の水位予測手法の提案, 土木学会論文集B1(水工学), Vol.74, No.4, pp.1_1459-1_1464, 2018
- 23) 高崎忠勝, 枝澤知樹, 川合将文: 石神井川下流域の流域雨量に関する検討, 東京都 令元.都土木技術支援・人材育成センター年報, pp.79-83, 2019
- 24) 国土交通省 水資源分野における気候変動への適応策のあり方検討会: 第5回気候変動による水資源への影響検討会 今年度の検討状況について, 2014
- 25) 奥泉宗一郎, 中津川誠, 白谷友秀: GISを用いた汎用的な流出計算手法の提案, 水文・水資源学会誌, Vol.29, No.1, pp.32-43, 2016
- 26) 日本学術会議: 回答 河川流出モデル・基本高水の検証に関する学術的な評価ー公開説明(質疑)ー, p.10, 2011
- 27) 公益財団法人日本下水道新技術機構: ストキャスティック手法を用いた雨天時浸入水対策に関する技術マニュアルー2018年3月ー, p.161, 2018
- 28) 国土交通省国土技術政策総合研究所: 污水管きょへの雨天時浸入水に関する調査報告書, p.5, 2002
(R3.1.26受付)



さとう かつみ
佐藤 克己
日本大学生産工学部
土木工学科 教授
日本下水道協会 特別会員



なかね すすむ
中根 進
中日本建設コンサルタント(株)
水工技術本部 技師長
日本下水道協会 特別会員



たかはし いわひと
高橋 岩仁
日本大学生産工学部
土木工学科 教授
日本下水道協会 特別会員



ほさか せいじ
保坂 成司
日本大学生産工学部
環境安全工学科 教授
日本下水道協会 特別会員



もりた ひろあき
森田 弘昭
日本大学生産工学部
土木工学科 教授
日本下水道協会 特別会員

Abstract

Research on Analysis of Infiltration of Stormwater Volume by AI Machine Learning of Flow Rate, Water Temperature Method Data

Katsumi Sato, Susumu Nakane, Iwahito Takahashi, Seiji Hosaka and Hiroaki Morita

The authors estimated the decrease in water temperature due to precipitation from the measured water temperature using a neural network, which is one of AI machine learning. It was shown that the non-excess probability represents a decrease in water temperature due to precipitation. As a result of measuring the water temperature and flow rate at the same point and analyzing the infiltration of storm water rate using this data, it was confirmed that there is a correlation with the non-excess probability. Then, it was shown that the non-excess probability represents the infiltration of stormwater rate ratio. In this study, the flow rate measured using machine learning was used as teacher data, and the estimated flow rate and the estimated flow rate in fine weather were derived from it. Then, it was confirmed that the neural network method can be reproduced best and is effective for this analysis. We also considered the selection of explanatory variables suitable for water temperature analysis, the appropriate measurement interval of water temperature data, and the survey area. At the same time, it was shown that the amount of infiltrated of stormwater between measurement points, can be analyzed by measuring either the flow rate or the water temperature.