

特集

水インフラとDX

AIによる 汚水管きよの常時浸入水に及ぼす 影響要因の分析

中日本建設コンサルタント株 中根 進

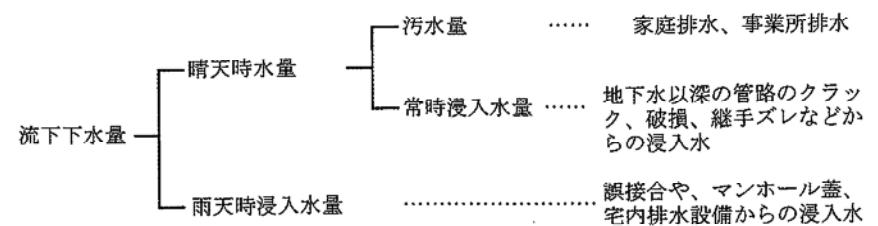
■ はじめに：下水道を取り巻く現状

わが国の社会資本は、戦後の高度成長期に急速に整備が進められ、下水道の整備も同じように整備されてきた。

下水管路のストックは、昭和40年代から平成10年代に集中的に整備され、今後老朽化による劣化が見込まれ、点検・調査、修繕・改築のコストの増大を招くとともに、不明水の増加や最悪の場合、管路の破損等による道路陥没や汚水の流出などに陥るリスクもはらんでいる。

そのため、そのリスクを把握し、適切に対応することが望まれ、平成27年度の下水道法の改正において、維持修繕基準が創設されるとともに、下水道事業計画の中に、維持・修繕および改築に関する内容を含めるよう求めている。これを踏まえ、自治体では下水道施設全体の管理を最適化するストックマネジメント計画を立案し、修繕および改築需要に対応することとしている。

分流式下水道の汚水管路を流下する下水量の



第1図 流下する下水量の内訳

内訳は、第1図のようになっている。

流下下水量のうち雨天時浸入水量や常時浸入水量は、後述する不明水と言われるもので、汚水ではないので、できる限り削減しなければならない。

処理場や中継ポンプ場では、料金徴収や維持管理のため、流入量や放流量を把握しており、流入量と降雨量を関連付けることにより雨天時浸入水量を把握できる。しかしながら、管きよの異状（クラック、破損、たるみ、取付け管の突き出しなど）から晴天日でも常時浸入していく常時浸入量については、TVカメラ調査等を行わなければ把握できない。そのTVカメラ調査でも、水量は把握できない。

筆者は、常時浸入水の原因となる汚水管路の異状と常時浸入水の現れる過程を経年数に対するワイル分布で表した⁽¹⁾。各異状の項目と常時浸入水のワイル分布を多重検定することによりクラック、破損、腐食の各項目が常時浸入水と同時に発現することを明らかにした。しかし、異状（クラック、破損、腐食）は、TV

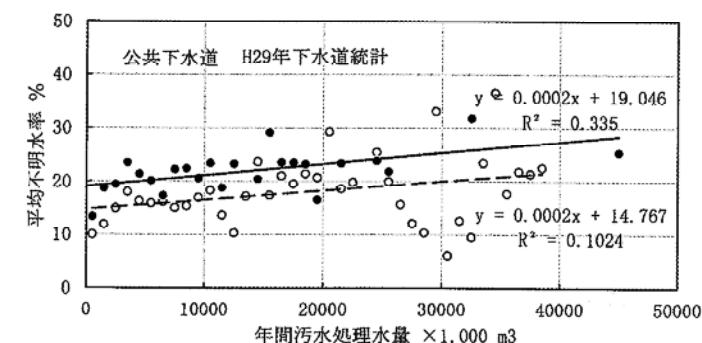
カメラ調査を行わなければ見つけることができず、膨大な量の下水管路のストックのため、その費用などから簡単には実施できないのが現状である。そのため、筆者は国土交通省国土技術政策総合研究所が公開している管渠劣化データベースVer.2⁽²⁾（以下、劣化データベース）を使い常時浸入水と下水道台帳に示される程度の管きよ諸元の間の関係を調べ、常時浸入水に及ぼす影響のある項目を分析することとした。

分析結果として下水道台帳にある項目と常時浸入水の間の相関が認められれば、常時浸入水に影響のある項目を持つ管きよから調査していくことにより、たとえば経年数の経た管きよからやみくもに実施していくより、影響のある項目の組み合わせにより効率的に実施できると考えた。

1 分流式下水道の不明水の実態

不明水は流下下水に対して有収水を除いたものとなっている。下水道管理者が下水道料金などとして把握できる汚水を有収水といっており、この有収水は測定できるものではなく、水道使用量から想定するもので物理量ではないが、第1図の常時浸入水量や雨天時浸入水量がこれに当る。

平成29年版下水道統計⁽³⁾には、我が国のお公共下水道の不明水率が示されている。



第2図 年間汚水処理水量と平均不明水率および分布による平均値の関係

$$\text{不明水率 (\%)} = \frac{\text{年間汚水処理水量} - \text{年間有収水量}}{\text{年間汚水処理水量} \times 100}$$

この不明水率について年間汚水処理水量を1,000,000m³単位で区分けして不明水率の算術平均をとると共に、区分け毎の不明水率をワイル分布で表し、ワイル分布による平均値を求め、年間汚水処理水量に対して図示すると第2図となる。

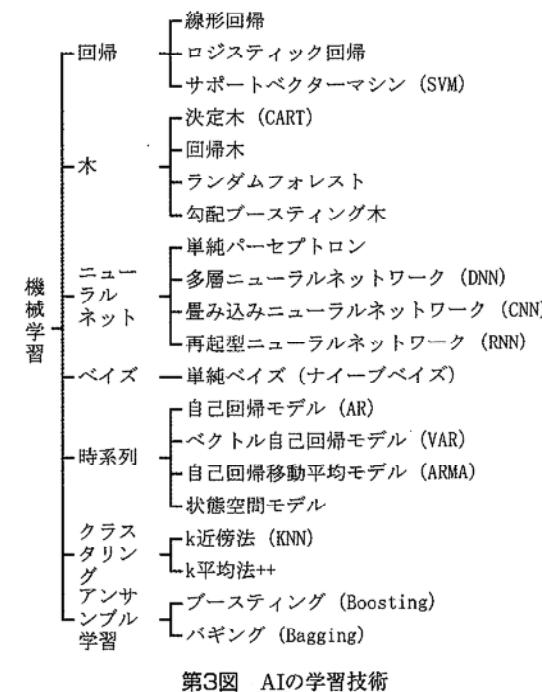
我が国の不明水の実態として年間汚水処理水量で異なるがワイル分布の平均値で年間汚水処理水量の20~30%が不明水（常時浸入水量+雨天時浸入水量）である。

2 AI学習によるコンクリート管の常時浸入水要因の分析

2-1 要因分析技術の概要

AI（人工知能）は、「認識・判断」「認識・理解」「予測・推論」「計画・最適化」などを実行する人間の知能を人工的に模倣するための総合的な概念技術である。人工的に知能を模倣するためには、法則やルール、事象を学習する必要があり、その学習技術を機械学習といい、多くの学習方法がある。機械学習の学習技術の種類を第3図に示す⁽⁴⁾。

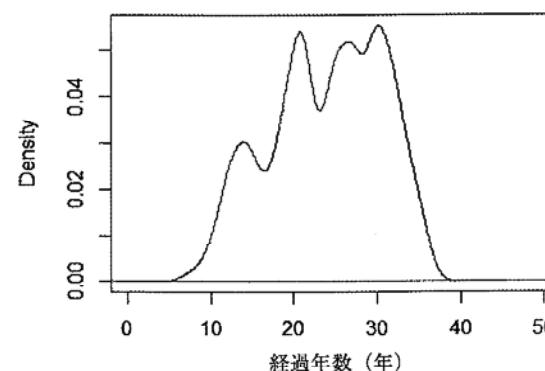
本稿では、管きよの下水道台帳から抽出できる諸元（管種、管径、路線延長、取付管本数、



第3図 AIの学習技術

経過年数、土被り)とTVカメラ調査による診断結果である「浸入水」を関連付けて、常時浸入水の影響が最も高いと思われる要因を管きよの諸元から検出しようとするものである。

前述劣化データベースにある診断項目の中にある「浸入水」に着目し、常時浸入水に関連する管きよの諸元との関係を分析することにより、常時浸入水のある管きよの諸元から浸入水の要因を推定する。従来、このような分析には数量化II類が使われているが、本稿ではAI学



第4図 経過年数のスパン数の分布

習のニューラルネットワークとランダムフォレストを用いた。使用した劣化データベースは、TVカメラ調査を行ったのちに劣化の判定基準⁽⁵⁾に基づき診断した結果が掲載されているが、諸元の内訳に対して調査数にバラツキがある。例として管きよ諸元の一つである経過年数に対する調査スパン数をノンパラメトリック分布で示すと、第4図となる。図のように経過年数によって調査数の偏りがある。

2-2 コンクリート管の常時浸入水要因の分析⁽⁶⁾

劣化データベース中の浸入水の診断項目は、浸入水_a、浸入水_b、浸入水_cとなっており、マンホールからマンホールの1スパン中に含まれているその状態の個数が記載されている。したがって、スパン中には浸入水_a、浸入水_b、浸入水_cの状態の個数が複数あることもある。

管きよのTVカメラ調査後の診断では、浸入水を含む複数項目の異状個数の割合(不良発生率)を計算し、スパン全体を評価する。

ここでは、浸入水についてのみ第1表の割合を使ってスパンごとに浸入水_A、浸入水_B、

第1表 不良発生率による全体のランク付けと判定基準

| スパン全体での評価 | ランク | 判定の基準(不良発生率) |
|-----------|-----|--|
| | A | 「aランク20%以上」もしくは「aランク+bランク40%以上」 |
| スパン全体での評価 | B | 「aランク20%未満」もしくは「aランク+bランク40%未満」もしくは「aランク+bランク+cランク60%以上」 |
| | C | 「aランク、bランクがなく、cランク60%未満」 |

第2表 浸入水の診断結果とニューラルネットワーク推定結果(コンクリート管)

| | 推定結果 | | | |
|------|-------|-------|-------|-------|
| | 浸入水A | 浸入水B | 浸入水C | 浸入水D |
| 浸入水A | 0 | 0 | 0 | 0 |
| 浸入水B | 0 | 4 | 1 | 1 |
| 浸入水C | 0 | 0 | 5 | 2 |
| 浸入水D | 15 | 359 | 309 | 3744 |
| 診断結果 | 15 | 363 | 315 | 3747 |
| 的中率 | 0.000 | 0.011 | 0.016 | 0.999 |

第3表 コンクリート管諸元のカテゴリ別スパン数

| 経過年数 年 | 路線延長 | | 管径 | | 取付管本数 | | 土被 | |
|-----------|-----------|-----------|------------|-----------|-----------|-----------|-----------|------|
| | スパン数 m | スパン数 m | mm スパン数 | 本 スパン数 | m スパン数 | 計 スパン数 | 計 スパン数 | |
| ~15 | 737 | ~16 | 812 | 24 | ~0 | 1821 | ~1.2 | 375 |
| ~20 | 709 | ~22 | 757 | 3659 | ~1 | 1086 | ~1.5 | 1278 |
| ~23 | 747 | ~26 | 769 | 749 | ~3 | 1060 | ~2 | 1272 |
| ~25 | 485 | ~30 | 626 | 800~ | 8 | 410 | ~3 | 699 |
| ~28 | 665 | ~36 | 740 | ~8 | 51 | ~5 | 669 | |
| ~30 | 549 | 37~ | 736 | 9~ | 12 | 5~ | 147 | |
| ~40 | 548 | | | | | | | |
| 計 | 4440 | 計 | 4440 | 計 | 4440 | 計 | 4440 | 計 |

浸入水_Cのランクを付けた。浸入水_a、浸入水_b、浸入水_cの中の個数がすべて0の場合を浸入水_Dとした。この結果を第2表の診断結果に示すが全4,440スパンに対して浸入水_Aは15スパンしかなく、3,747スパンが浸入水_Dであり健全なものである。

スパンごとの浸入水ランクを目的変数とし、前述、管きよの諸元を説明変数としAI学習により常時浸入水の要因となっている説明変数を推定する。AI学習にはニューラルネットワーク、ランダムフォレストを使った。学習結果は、学習による推定結果とDBの調査診断結果を比較することによって的中率で示す。

ニューラルネットワークでの学習結果(第2表中の推定結果スパン数)は、劣化データベースの調査診断結果と異なっており、一致、不一致を的中率として表わすと全体では99.9%であるが、浸入水ランクA、B、Cの的中率は1.0%程度であった。ランダムフォレストの学習結果は、以降に示すが、ニューラルネットワークより良好な結果を得たため、AI学習方法としてランダムフォレストを使用した。

2-3 ランダムフォレストによる常時浸入水要因の分析

(1) コンクリート管諸元のカテゴリ別スパン数

ランダムフォレストは、学習用のデータをランダムにサンプリングして多数の決定木を作成し、作成した決定木をもとに多数決で結果を決める方法である。精度、汎用性が高く扱いやす

い分析手法と言われている。

コンクリート管諸元の内訳は、前掲第4図では経過年数を示したが調査スパン数に大きな偏りがある。管きよの諸元を第3表のようにスパン数がなるべく平準になるようにその内訳を分け、カテゴリ値としてランダムフォレストにより浸入水ランクの推定を行う。

ランダムフォレストによる浸入水ランクの分類推定結果は第4表となる。

第4表 浸入水の診断結果とランダムフォレスト推定結果

| | 推定結果 | | | |
|------|-------|-------|-------|-------|
| | 浸入水A | 浸入水B | 浸入水C | 浸入水D |
| 浸入水A | 1 | 0 | 0 | 0 |
| 浸入水B | 0 | 54 | 0 | 0 |
| 浸入水C | 0 | 0 | 70 | 0 |
| 浸入水D | 14 | 309 | 245 | 3747 |
| 診断結果 | 15 | 363 | 315 | 3747 |
| 的中率 | 0.067 | 0.149 | 0.222 | 1.000 |

TVカメラ調査診断結果で浸入水Aと判定されたスパン数は15であり、学習による推定では、浸入水Aと推定したスパン数が1であり、誤って、14スパンを浸入水Dと推定し、浸入水Aの的中率は6.7%であった。浸入水Bは、363スパン中54スパンしか推定しておらず、的中率は14.9%しかない。同様に浸入水Cは、315スパン中70スパンでの中率は22.2%しかない。

浸入水Dは、100%の的中率であるが、浸入水A、浸入水B、浸入水Cの要因を見出すことが目的であり、このような分析結果では浸入水の要因を見つけることはできない。浸入水A、浸入水B、浸入水Cの的中率の悪い理由とし

て、浸入水A（15スパン）、浸入水B（363スパン）、浸入水C（315スパン）とデータ数が少なく、浸入水D（健全3747スパン）が圧倒的に多く、浸入水ランク別のスパンデータ数の偏り、不均衡が推定精度の低下の原因と考えられる。

ランダムフォレスト法は、ランダムにデータを抽出し、決定木を作り、説明変数を絞り込んでいくので、データの不均衡の問題はないと思われたが、浸入水ランクデータ数を補正して解析することとした。

(2) クラスターによるデータ数補正

アンダーサンプリングと云われる浸入水Dを他のランクのスパン数程度減らす方法によりデータ数を補正する。

階層的クラスター分析という、スパンの類似度（距離）に基づいて、最も似ているスパンを集めてクラスターを作る手法がある。

浸入水Dの管きよ諸元（管種、管径、路線延長、取付管本数、経過年数、土被り）に何らかの類似性（距離）があるかを調べ、類似性のある10のクラスター（グループ）に分ける。

本稿ではk平均法（k-means）というアルゴリズムを使い、クラスターの平均値からk個（=10）のクラスター数に分類した。クラスターに分類したスパン数を第5表（中列）に示す。

第5表 浸入水Dのクラスター別抽出スパン数

| クラスター (グループ) | 浸入水D のスパン 数 | 浸入水D の抽出ス パン数 |
|-----------------|-------------------|---------------------|
| 1 | 212 | 20 |
| 2 | 705 | 67 |
| 3 | 347 | 33 |
| 4 | 494 | 47 |
| 5 | 524 | 50 |
| 6 | 295 | 28 |
| 7 | 160 | 15 |
| 8 | 399 | 38 |
| 9 | 264 | 25 |
| 10 | 347 | 33 |
| 計 | 3747 | 356 |

次に10個に分けた浸入水Dのクラスター（グループ）から、浸入水B（363スパン）と浸入水C（315スパン）と同程度数（345スパン）を

各クラスター（グループ）のスパンから均等に抽出するものとして比例配分して抽出数を設定する。クラスター（グループ）ごとに一様乱数を発生させて、設定スパン数（第5表（右列））とスパンを抽出した。

(3) データ数補正後のカテゴリ別分析結果

データ数補正後のランダムフォレストによる分析結果を第6表に示す。

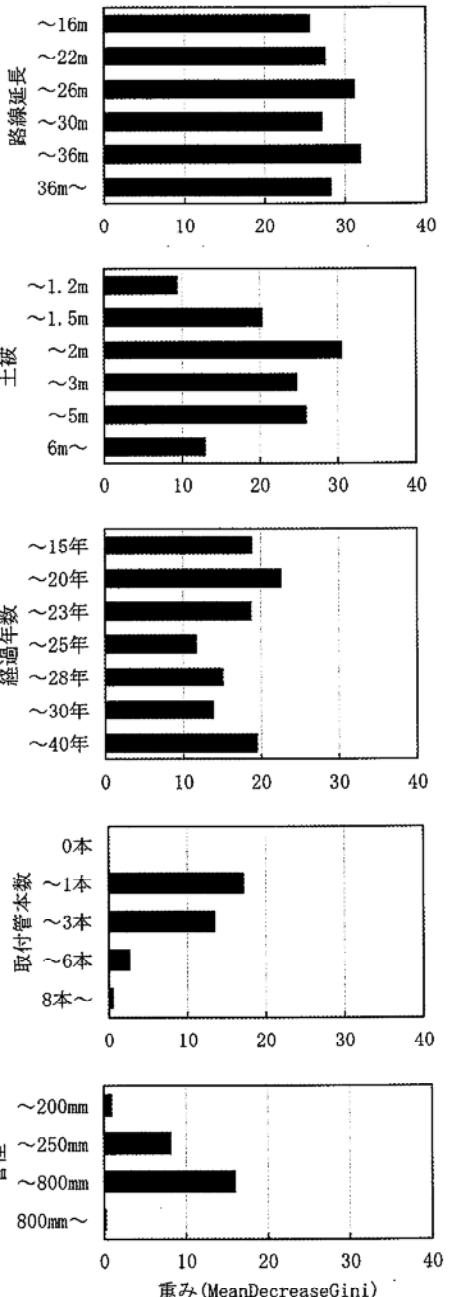
第6表 浸入水診断結果の推定分類と的中率

| | 推定結果 | | | |
|------|-------|-------|-------|-------|
| | 浸入水A | 浸入水B | 浸入水C | 浸入水D |
| 浸入水A | 13 | 0 | 0 | 0 |
| 浸入水B | 2 | 362 | 23 | 0 |
| 浸入水C | 0 | 1 | 292 | 0 |
| 浸入水D | 0 | 0 | 0 | 3747 |
| 診断結果 | 15 | 363 | 315 | 3747 |
| 的中率 | 0.867 | 0.997 | 0.927 | 1.000 |

「浸入水A」が15スパンあるにもかかわらず「浸入水B」を2スパンと誤って推定分類てしまっている。しかしながら、「浸入水D」のデータ数を減らしたことにより前掲第4表に示す推定分類の的中率より大幅に向上し、「浸入水A」「浸入水B」「浸入水C」を的中させることができた。

この分析結果による常時浸入水に影響を与える要因（管きよ諸元）のカテゴリ別をさらに細分化した重みを第5図に示す。重みの大きい順に常時浸入水に影響を与えており経過年数や取付管本数は路線延長に較べて影響が小さい結果となった。

第5図に示す重みから路線延長が、最も重い項目であり22~36m、次に土被り1.5~5.0m、経過年数16~20年であり、これらに該当する下水管路を優先的にTVカメラなどの調査を実施することにより、常時浸入水やクラックなどの異状のあるスパンを膨大なストックの中から効率的に抽出できると考えられる。



第5図 常時浸入水影響要因のカテゴリごとの重み

3 AI技術の応用事例

3-1 ニューラルネットワーク法による雨天時浸入水量解析

常時浸入水の要因となる管きよ諸元をランダ

ムフォレストで推定したが、筆者はAIの学習技術の一つであるニューラルネットワーク法により処理場の流量や管渠内での流量測定の時系列データを目的変数として説明変数（降雨量、カレンダー情報）を使って回帰し、計測流量を再現している⁽⁷⁾。得られた説明変数に対する重みを用いて降雨をなし（0）として再計算することにより雨天時の晴天時水量を推定している。

解析結果の一部を第6図に示す。流入水量の計測値を打点（●印）で示し、ニューラルネット法で回帰した流入水量を実線で示す。打点した計測流量と回帰した推定線はよく一致している。降雨における推定晴天時流量（降雨のない流量）を破線で示す。実線の流入水量と破線の推定晴天時流量の差が雨天時浸入水量となる。

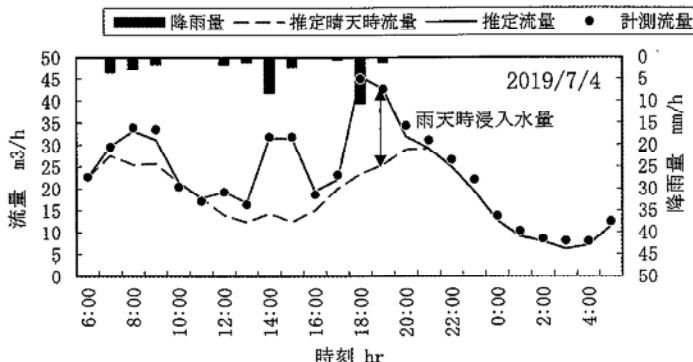
3-2 脱水機の操作因子と脱水ケーキ含水率⁽⁸⁾

脱水機の操作因子や気象条件（①気温、雨量、②PAC注入量、③濃縮槽pH、④生汚泥固体物割合、消化汚泥固体物割合、余剰汚泥固体物割合、⑤高分子凝集剤13種類、⑥高分子凝集剤注入率、⑦脱水機ろ過速度、⑧カレンダー情報（月、曜日））を説明変数として脱水ケーキ含水率（目的変数）をニューラルネットワークで解析し、脱水ケーキ含水率に影響を与える最適な操作因子を明らかにし、脱水機投入汚泥の性状や操作因子（ろ過速度、凝集剤注入率など）を使い運転管理に使用したいと考えた。

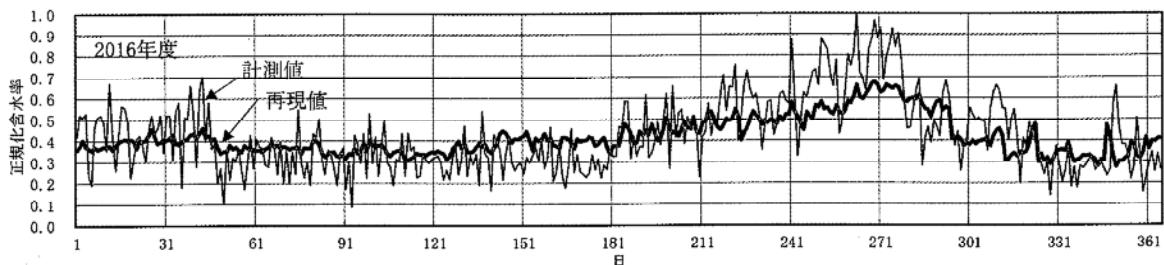
ある年度の脱水ケーキの計測値を正規化した含水率を細線で、脱水機操作因子や気象条件の説明変数を与えて求めた含水率を太い実線で第7図に示す。

おわりに：課題と今後の展望

筆者は、本稿では示していないが、サポートベクターマシン、ペイズ推計、ベクトル自己回



第6図 計測流量・降雨量と推定流量と推定晴天時流量の推移



第7図 脱水ケーキ含水率と回帰脱水ケーキ含水率の推移

帰モデルなどのAI技術を使って説明変数の多い回帰やデータ数の多い分類に大変役立っているが、データの種類や学習結果によって使い分けている。また、データをそのまま利用できないこともある。たとえば、2章に示した解析事例では、浸入水Dのデータ数をアンダーサンプリング法で調整することにより、ランダムフォレスト学習によって常時浸入水に影響を与える要因（管きよ諸元）を推定した。また、脱水ケーキ含水率では、おおむね含水率を推定できているが、雨天時浸入水量の推定のような精度に達しておらず、人力以外の説明変数を見つける必要があるなど課題は多いと感じている。

下水道関連でも国土交通省が開発し、(公社)日本下水道協会と共同運営する「下水道全国データベース」⁽⁹⁾が立ち上がるなど情報化が促進されており、いろいろな情報が得られるようになり、AIによる分析の機会が多くなると思われる。

<参考文献>

- (1) 中根進：“カブラン・マイヤー法によるコンクリート管の異状発現順位の推定”、下水道協会誌論文集、Vol.55、No.672（平成30年10月）
- (2) 国土技術政策総合研究所：管渠劣化データベースVer.2 <http://www.nirim.go.jp/lab/ebg/rekka-db.html>
- (3) (公社)日本下水道協会：平成29年度版 下水道統計、第74号
- (4) (株)SPJ：webサイト、決定木の2つの種類とランダムフォレストによる機械学習アルゴリズム入門（2021年1月10日確認）
- (5) (公社)日本下水道協会：“下水道維持管理指針 実務編 2014年版”、pp.111-119
- (6) 谷川雄哉・中根進：“AIによる污水管きよの常時浸入水に及ぼす影響要因の分析”、2020年第57回下水道研究発表会、N-7-2-2
- (7) 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”、下水道協会誌論文集（平成20年8月）
- (8) 山田瑠莉子・中根進：“AIによる時系列データ等の解析事例”、(公社)全国上下水道コンサルタント協会、令和元年度技術報告集、第34号（令和2年8月）
- (9) (公社)日本下水道協会：下水道全国データベース www.jswa.jp/database/

(筆者紹介はp.106参照)